

SVEUČILIŠTE U ZAGREBU  
FAKULTET STROJARSTVA I BRODOGRADNJE

# **ZAVRŠNI RAD**

**Bepo Lukač**

Zagreb, 2018.

SVEUČILIŠTE U ZAGREBU  
FAKULTET STROJARSTVA I BRODOGRADNJE

# ZAVRŠNI RAD

Mentor:

Dr. sc. Hrvoje Cajner, dipl. ing.

Student:

Bepo Lukač

Zagreb, 2018.

Izjavljujem da sam ovaj rad izradio samostalno koristeći znanja stečena tijekom studija i navedenu literaturu.

Zahvaljujem se svome mentoru **dr. sc. Hrvoju Cajneru** na stručnoj pomoći i savjetima kojima su mi omogućili da uspješno završim ovaj rad.

Zahvaljujem se obitelji na pruženom strpljenju i povjerenju koje su mi pružili tijekom studija i tijekom pisanja ovog rada.

Bepo Lukač



SVEUČILIŠTE U ZAGREBU  
**FAKULTET STROJARSTVA I BRODOGRADNJE**



Središnje povjerenstvo za završne i diplomske ispite  
Povjerenstvo za završne ispite studija strojarstva za smjerove:  
proizvodno inženjerstvo, računalno inženjerstvo, industrijsko inženjerstvo i menadžment, inženjerstvo  
materijala i mehatronika i robotika

Sveučilište u Zagrebu	
Fakultet strojarstva i brodogradnje	
Datum: 02-2018	Prilog
Klasa: 602-04/18-6/3	
Ur.broj: 15-1703-18-49	

## ZAVRŠNI ZADATAK

Student: Bepo Lukač Mat. br.: 0035199346  
Naslov rada na hrvatskom jeziku: Analiza vremena komisioniranja pri različitim parametrima  
Naslov rada na engleskom jeziku: Analysis of commissioning time using different parameters

### Opis zadatka:

Optimizacija i prilagodba skladišnih prostora pa tako i rasporeda artikala u samom regalu ima za cilj smanjivanje vremena izuzimanja te zaštitu radnika od preopterećenja. S tom premisom osmišljen je eksperiment koji bi trebao dati odgovore na pitanja kako i u kojoj mjeri utječu određeni parametri na pokazatelje efikasnosti i ergonomije u procesu komisioniranja. U radu je potrebno:

1. Opisati eksperiment.
2. Izračunati sve relevantne statističke pokazatelje.
3. Analizirati utjecajne faktore.
4. Posebice se osvrnuti na usporedbu dobnih skupina radnika do 50 i iznad 50 godina.

Zadatak zadan:  
30. studenog 2017.

Rok predaje rada:  
1. rok: 23. veljače 2018.  
2. rok (izvanredni): 28. lipnja 2018.  
3. rok: 21. rujna 2018.

Predviđeni datumi obrane:  
1. rok: 26.2. - 2.3. 2018.  
2. rok (izvanredni): 2.7. 2018.  
3. rok: 24.9. - 28.9. 2018.

Zadatak zadao:  
Dr. sc. Hrvoje Cajner, doc.

Predsjednik Povjerenstva:

  
Izv. prof. dr. sc. Branko Bauer

## SADRŽAJ

SADRŽAJ .....	I
POPIS SLIKA .....	III
POPIS TABLICA.....	IV
SAŽETAK.....	V
SUMMARY .....	VI
1. UVOD.....	1
2. KONCEPT POKUSA.....	2
2.1. Parametri pokusa.....	3
3. TEORIJSKA RAZRADA METODE.....	5
3.1. Varijabilni i kontrolirani faktori.....	5
3.2. Analiza varijance.....	5
3.3. Regresijska analiza.....	5
4. ANALIZA PODATAKA ZA SKUPINU DO 50 GODINA .....	6
4.1. Sakupljeni podaci .....	6
4.2. Korelacija parametara i odziva .....	6
4.3. Model za skupinu do 50 godina .....	7
4.4. Analiza rasipanja.....	14
4.4.1. Volumen.....	14
4.4.2. Masa tereta .....	15
4.4.3. Visina police .....	16
4.5. Analiza odziva po faktorima .....	17
4.5.1. Utjecaj mase na vrijeme odziva za skupinu do 50 godina .....	17
4.5.2. Utjecaj visine na vrijeme odziva za skupinu do 50 godina.....	20
4.5.3. Utjecaj volumena na vrijeme odziva za skupinu do 50 godina.....	22
5. ANALIZA PODATAKA ZA SKUPINU 50 I VIŠE GODINA .....	25
5.1. Sakupljeni podaci .....	25
5.2. Korelacija parametara i odziva .....	25
5.3. Model za skupinu 50 i više godina.....	25
5.4. Analiza rasipanja.....	32
5.4.1. Volumen.....	32
5.4.2. Masa tereta .....	32
5.4.3. Visina police .....	33
5.5. Analiza odziva po faktorima .....	34
5.5.1. Utjecaj mase na vrijeme odziva za skupinu 50 i više godina.....	34
5.5.2. Utjecaj visine na vrijeme odziva za skupinu 50 i više godina .....	37
5.5.3. Utjecaj volumena na vrijeme odziva za skupinu od 50 i više godina .....	39
6. USPOREDBA DOBNIH SKUPINA.....	41
6.1. Usporedba s obzirom na visinu police .....	41
6.2. Usporedba s obzirom na masu .....	43
6.3. Usporedba s obzirom na volumen.....	44

---

7. ZAKLJUČAK.....	45
LITERATURA.....	46
PRILOZI.....	47

**POPIS SLIKA**

Slika 1.	Izgled regala i površine za odlaganje[1].....	2
Slika 2.	Grafički prikaz regala i kutija.....	3
Slika 3.	Mreža korelacija .....	7
Slika 4.	Opis skupa podataka funkcijom .....	10
Slika 5.	3D površine neoznačenih kutija .....	12
Slika 6.	3D površine označenih kutija .....	13
Slika 7.	Rasipanje odziva s obzirom na volumen .....	15
Slika 8.	Rasipanje odziva s obzirom na masu tereta.....	15
Slika 9.	Rasipanje tereta s obzirom na visinu police .....	16
Slika 10.	Utjecaj mase kod neoznačenih kutija za skupinu do 50 godina .....	18
Slika 11.	Utjecaj mase kod označenih kutija za skupinu do 50 godina.....	19
Slika 12.	Utjecaj visine police kod neoznačenih kutija za skupinu do 50 godina .....	20
Slika 13.	Utjecaj visine police kod označenih kutija za skupinu do 50 godina.....	21
Slika 14.	Utjecaj volumena kod neoznačenih kutija za skupinu do 50 godina .....	23
Slika 15.	Utjecaj volumena kod označenih kutija za skupinu do 50 godina .....	24
Slika 16.	Opis skupa podataka za skupinu 50 i više godina .....	28
Slika 17.	3D površine neoznačenih kutija kod skupine 50 i više godina .....	30
Slika 18.	3D površine označenih kutija kod skupine 50 i više godina .....	31
Slika 19.	Rasipanje odziva s obzirom na volumen za 50 i više godina.....	32
Slika 20.	Rasipanje odziva s obzirom na masu za 50 i više godina .....	33
Slika 21.	Rasipanje odziva s obzirom na visinu police za 50 i više godina .....	33
Slika 22.	Utjecaj mase kod neoznačenih kutija za skupinu 50 i više godina .....	35
Slika 23.	Utjecaj mase kod označenih kutija za skupinu 50 i više godina .....	36
Slika 24.	Utjecaj visine police kod neoznačenih kutija za skupinu od 50 i više godina .....	37
Slika 25.	Utjecaj visine police kod označenih kutija za skupinu od 50 i više godina .....	38
Slika 26.	Utjecaj volumena kod neoznačenih kutija za skupinu od 50 i više godina.....	39
Slika 27.	Utjecaj volumena kod označenih kutija za skupinu od 50 i više godina.....	40
Slika 28.	Analiza varijance dobnih skupina kategorizirano po visini .....	42
Slika 29.	Analiza varijance dobnih skupina kategorizirano po masi.....	43
Slika 30.	Analiza varijance dobnih skupina kategorizirano po volumenu .....	44

---

**POPIS TABLICA**

Tablica 1. Parametri pokusa .....	3
Tablica 2. Statističke karakteristike parametara .....	4
Tablica 3. Sakupljeni podaci .....	6
Tablica 4. Analiza varijance modela za neoznačene kutije do 50 godina .....	8
Tablica 5. Analiza varijance modela za označene kutije do 50 godina .....	9
Tablica 6. Regresijska analiza modela za neoznačene kutije do 50 godina .....	10
Tablica 7. Regresijska analiza modela za označene kutije do 50 godina .....	10
Tablica 8. Sakupljeni podaci za skupinu 50 i više godina .....	25
Tablica 9. Analiza varijance za neoznačene kutije za 50 i više godina .....	26
Tablica 10. Analiza varijance za označene kutije za 50 i više godina .....	27
Tablica 11. Regresijska analiza modela za neoznačene kutije za 50 i više godina .....	28
Tablica 12. Regresijska analiza modela za označene kutije za 50 i više godina .....	28



---

**SAŽETAK**

Tema ovog rada je analiza podataka o vremenima izuzimanja dobivenih iz provedenog pokusa gdje su ispitanici podijeljeni u dvije dobne skupine simulirali ručno izuzimanje. Obradom podataka i primjenom statističkih alata dobiveni su grafički i statistički pokazatelji o utjecaju pojedinih faktora na vrijeme izuzimanja. Svi utjecaji detaljno su analizirani po razinama faktora. Posebna pozornost pridana je usporedbi dobnih skupina ispitanika do 50 i iznad 50 godina. Gledano je postoji li značajna razlika između vremena izuzimanja dviju dobnih skupina i koji faktori najviše utječu na pojavu razlike.

Ključne riječi: vrijeme izuzimanja, utjecajni faktori, analiza varijance

---

**SUMMARY**

This paper deals with the analysis of data gathered on excerption time in the process of manual picking goods from storage location. Data was gathered by conduting an experiment where participants, split in two groups based on age, were conducting manual goods excerption. Graphs and statistical information, showing excerption times and how much they are influenced by influential factors, were gathered by data processing. Special attention was given to comparison of data of two different age groups. One group consisted of participants aged 30 to 50, while other was comprised of participants aged 50 and more. Analysis was carried out to see if there is significant difference in excerption time between the two groups, and if so, which of the factors influence it the most.

Key words: excerption time, influential factors, analysis of variance

## 1. UVOD

U današnje vrijeme, kada je sveopća optimizacija procesa ključna za smanjenje troškova, a samim time i ostvarivanje konkurentnosti, velika se pozornost pridaje skladištenju dobara. Općeprihvaćena praksa je težnja minimizaciji potrebe za skladištenjem u bilo kojoj vrsti poduzeća, a idealno bi bilo kada potreba za skladištenjem uopće ne bi postojala. Općenito, smatra se da je skladištenje izravni trošak za svako poduzeće zato što ne stvara dodatnu vrijednost, a zauzima prostor i nekretnine. Unatoč težnji, većina poduzeća primorana je svejedno imati skladišta, pa makar i minimalna, zbog prirode svog poslovanja ili proizvodnog procesa koji ne omogućuju uvijek trenutnu (*Just-In-Time*) distribuciju proizvoda.

Skladišta se također unapređuju napretkom tehnologije i industrije upravo zbog potrebe da u konačnici generiraju što manji trošak, odnosno da čine što je manji mogući dio cijene koštanja nekog proizvoda. Postoje mnoge vrste skladišta i dok ima i velikih potpuno automatiziranih skladišta od kojih su neka dovedena do maksimalne učinkovitosti koju današnja tehnologija pruža, postoje i manja skladišta koja služe za skladištenje delikatnijih dobara, a zbog njihove relativno male zapremnine automatizacija istih nije isplativa. U takvim skladištima zaposleni su operateri koji se bave komisioniranjem, odnosno skladištenjem i izuzimanjem robe iz skladišta, a iako se nadzor toka dobara može obavljati pomoću računalnih rješenja, sam posao komisioniranja obavlja se ručno.

U ovom radu analizirati će se upravo utjecaj različitih faktora na vrijeme izuzimanja u malom skladištu gdje se komisioniranje obavlja ručno od strane operatera. Također, usporediti će se podaci i rezultati analize za dvije različite starosne skupine. Analiza će se provesti na temelju podataka dobivenih iz istraživanja od strane doc. dr. Brigitte Gajšek i njenog tima sa Sveučilišta u Mariboru, koji su proveli pokus u svojem laboratoriju.


## 2. KONCEPT POKUSA

Pokus je koncipiran na način da se uzme što više utjecajnih parametara u obzir i dobije što veća obuhvaćenost realnih uvjeta rada s ciljem dobivanja kvalitetnih podataka za kasniju provedbu analize. Ideja je bila ponajprije uzeti nekoliko različitih profila ljudi iz dvije starosne skupine: prva skupina su ljudi starosti do 50 godina, a druga 50 i više godina života. Pokusni ispitanici su simulirali operatere pri komisioniranju robe u skladištu te se za vrijeme njihovog rada mjerilo vrijeme koje im je potrebno da izuzmu robu različitih dimenzija i mase sa polica regala na više različitih visina [Slika 1]. Sva roba se izuzimala i stavljala na površinu za odlaganje nasuprot regalu koja je u pokusu predstavljala pokretnu traku ili mjesto komisioniranja koje bi se u stvarnosti koristilo.



**Slika 1. Izgled regala i površine za odlaganje[1]**

Odabrano je sedmero različitih osoba koje su izuzimale kutije četiriju različitih iznosa masa i triju različitih volumena sa polica na pet različitih visina. Na svaku o određenih visina nasumično su postavljene kutije različitih volumena i visina [Slika 2.]. Parametri mase, volumena i visine polica su detaljnije obrađeni u poglavlju četiri ovoga rada. Također, ispitivanje je prvo provedeno sa kutijama na kojima nisu bile označene mase istih, a zatim su na te iste kutije stavljeni iznosi mase kutija.



Slika 2. Grafički prikaz regala i kutija

## 2.1. Parametri pokusa

Korišteni parametri kod obje zadane dobne skupine su volumen i masa kutija te položaj, odnosno visina police na kojoj se kutija nalazi. Podaci su popisani u sljedećoj tablici.

Tablica 1. Parametri pokusa

Dimenzije kutija (visina x širina x dubina) [cm]	Masa kutija [kg]	Visina police regala [cm]	Visina površine za odlaganje [cm]
Velika (L): 31 x 37 x 45	0,1; 1; 5; 10	13; 56; 100; 143; 185	76
Srednja (M): 20 x 30 x 40			
Mala (S): 7 x 11 x 18			

U tablici 2 vidi se prikaz karakteristika triju navedenih parametara, njihovih minimuma i maksimuma, srednjih vrijednosti i standardne devijacije. Valja napomenuti da se za volumen ne mogu dobiti srednja vrijednost i standardna devijacija budući da se radi o kategoričkom, a ne numeričkom parametru. Iste veličine, odnosno razredi parametara korišteni su kroz cijeli pokus, za obje dobne skupine i za označene i neoznačene kutije. Vremena izuzimanja prvo su mjerena za neoznačene, a zatim za označene kutije kako bi se dobio uvid i u psihološki učinak

davanja informacija o predmetu izuzimanja radniku koji izuzimanje obavlja. Utjecaj označenosti, odnosno neoznačenosti kutije pratiti će se i komentirati usporedno kroz analizu utjecaja svakog parametra te kroz krajnju usporednu analizu prema dobnim skupinama.

**Tablica 2. Statističke karakteristike parametara**

<b>Parametar</b>	<b>Jedinica</b>	<b>Tip parametra</b>	<b>Min</b>	<b>Max</b>	<b>Srednja vrijednost</b>	<b>Standardna devijacija</b>
Volumen	-	Kategorički	Mali	Veliki	-	3 razine
Masa	kg	Numerički	0,10	10,00	4,03	3,80
Visina police	cm	Numerički	13,00	185,00	99,40	61,02

### 3. TEORIJSKA RAZRADA METODE

Prilikom provedbe samog pokusa uzima se u obzir više varijabilnih i kontroliranih faktora. Nad rezultatima se tada provodi niz statističkih metoda kako bi se kasnije mogli polučiti relevantni i točni zaključci. Neke od analiza koje se koriste su analiza varijance i regresijska analiza.

#### 3.1. Varijabilni i kontrolirani faktori

Varijabilni faktori (ulazi) su faktori koji se tijekom provedbe pokusa mijenjaju na unaprijed određen način te na unaprijed određene iznose kako bi se dobili rezultati točno željene raznolikosti. Ovakav ishod je poželjan kako bi kasnije zaključci dobiveni analizom rezultata bili što obuhvatniji i reprezentativniji u realnom okolišu. Kontrolirani faktori (vanjski i unutarnji utjecaji) su oni faktori za koje se smatra da bi mogli utjecati na rezultate provođenog mjerenja, a da se to ne želi te se stoga oni moraju održavati na konstantnim razinama i po potrebi nadzirati. Planer pokusa mora unaprijed znati koji mu je željeni ishod, kako bi mijenjanjem određenih te nadziranjem drugih faktora (parametara) to mogao postići. Planer mora omogućiti provedbu temeljite analize iz, u pravilu, relativno malog broja rezultata (izlaza) kako bi se za dobivene krajnje zaključke moglo reći da su odraz realnog ponašanja promatrane materije u realnom okolišu.

#### 3.2. Analiza varijance

Analiza varijance je metoda koja uspoređuje prosjeke uzoraka kako bi se utvrdilo postoje li razlike između prosjeka populacija [2]. Ovom metodom moguće je procijeniti koliko je neki pojedini izvor utjecao na varijabilnost dobivenih rezultata. Analizom varijance provjeravaju se promjene aritmetičkih sredina uzoraka. Primjena analize varijance moguća je ako se mjerena varijabla normalno distribuira [3].

#### 3.3. Regresijska analiza

Regresijska analiza ispituje ovisnost jedne zavisne varijable o jednoj ili više nezavisnih varijabli. Iz analize se želi dobiti analitički izraz takve povezanosti [4]. Osnovu regresijske analize čini regresijski model koji je u suštini algebarski model kojim se analitički izražava statistički odnos između dvije ili više pojava. Model može biti deterministički ili statistički. Kod determinističkog modela za svaku vrijednost nezavisne varijable  $x$  jednoznačno je označena vrijednost  $y=f(x)$ . Statistički model opisuje vrijednost zavisne varijable  $y=f(x)+\varepsilon$  kada zavisna varijabla  $y$  nije jednoznačno određena za zadanu vrijednost nezavisne varijable  $x$ , pri čemu je  $\varepsilon$  stohastička varijabla, odnosno matematički predodčen iznos svih okolišnih uvjeta.

## 4. ANALIZA PODATAKA ZA SKUPINU DO 50 GODINA

Nakon svakog pokusa prikupljeni podaci moraju se obraditi na način da ih se pomoću matematičkog modela oblikuje u neku matematičku funkciju. Jednom kada se dobije matematička funkcija koja aproksimativno opisuje sakupljene podatke oni se mogu analizirati.

### 4.1. Sakupljeni podaci

Kao što je već navedeno, prilikom pokusa prvo su korištene kutije neoznačenih masa, a kasnije su na te isto kutije stavljene oznake s ispisanom masom tereta. Sljedeća tablica sadrži informacije o prikupljenim podacima podijeljene prema provođenju pokusa, dakle prema neoznačenim i označenim kutijama.

**Tablica 3. Sakupljeni podaci**

Kutije	Jedinica	Veličina uzorka	Min	Max	Srednja vrijednost	Standardna devijacija
Neoznačene	s	446	1,00	6,60	2,62	0,93
Označene	s	447	1,30	7,70	3,09	1,02

Iz priložene tablice 3 vidljivo je kako je prosječno vrijeme izuzimanja neoznačenih kutija kraće od prosječnog vremena izuzimanja označenih kutija, što je i za očekivati budući da bez označene mase radnici tijekom obavljanja posla zaborave na eventualni napor. Nadalje, može se reći i da su skloni zadati si određeni tempo rada i ne žele previše odstupati od tog tempa, čemu svjedoči manja standardna devijacija kod neoznačenih kutija.

### 4.2. Korelacija parametara i odziva

Korištenjem programskog paketa Design Expert 11 može se dobiti uvid u korelaciju pojedinog parametra i vremena odziva u matričnom prikazu [Slika 3.], a odabirom pojedinog polja dobije se grafički prikaz svih odziva u odnosu na odabrani parametar što će se koristiti u radu tijekom analize rasipanja. Matrica korelacija prikazuje korelaciju na način da što je veća korelacija između pojedinog parametra i odziva, to je crvenije polje na kojem se križaju redak odabranog parametra i stupac odabranog odziva. Naravno da je korelacija nekog parametra sa samim sobom potpuna, odnosno jednaka jedan, te su ta polja najcrvenija. Stoga sva polja koja nisu u području ograđenom pravokutnikom treba zanemariti.



	Run	Block	A:Volumen	B:Masa tereta	C:Visina police	Vrijeme izuzimanja	Vrijeme oznacene kutije
Run		X	X				
Block	X		X	X	X	X	X
A:Volumen	X	X		X	X	X	X
B:Masa tereta		X	X			X	X
C:Visina police		X	X			X	X
Vrijeme izuzimanja		X	X	X	X		X
Vrijeme oznacene kutije		X	X	X	X	X	

Slika 3. Mreža korelacija

#### 4.3. Model za skupinu do 50 godina

Sakupljeni podaci aproksimirani su kvadratnim modelom s interakcijama za svaku od veličina volumena i s obzirom na označenost i neoznačenost kutija. Članovi i faktori modela navedeni su u formulama u drugom dijelu ovog potpoglavlja. Prikladnost modela može se vidjeti i iz analize varijance koju također generira softverski program. Prema malim iznosima p vrijednosti vidi se prikladnost modela, što potvrđuje i programski generiran odgovor „nije značajan“ za vrijednost „ostatak“, odnosno program želi reći da je ostatak između skupa stvarnih podataka i aproksimacije skupa podataka zanemariv. Drugim riječima, skupovi se dobro poklapaju.

Tablica 4. Analiza varijance modela za neoznačene kutije do 50 godina

Izvor	Suma kvadrata	Stupnjevi slobode	Kvadratna sredina	F-vrijednost	p-vrijednost	
Blok	0,0074	4	0,0018			
<b>Model</b>	0,0367	10	0,0037	142,90	< 0,0001	Značajan
A-Volumen	0,0026	2	0,0013	51,06	< 0,0001	
B-Masa	0,0216	1	0,0216	838,97	< 0,0001	
C-Visina police	0,0004	1	0,0004	14,22	0,0002	
AB	0,0001	2	0,0001	2,18	0,1145	
B <sup>2</sup>	0,0020	1	0,0020	79,11	< 0,0001	
C <sup>2</sup>	0,0015	1	0,0015	59,30	< 0,0001	
AB <sup>2</sup>	0,0005	2	0,0003	10,43	< 0,0001	
<b>Ostatak</b>	0,0111	431	0,0000			
Odstupanje	0,0007	30	0,0000	0,9615	0,5273	Nije značajno
Čista pogreška	0,0103	401	0,0000			
<b>Suma kvadrata odstupanja</b>	0,0552	445				

Tablica 5. Analiza varijance modela za označene kutije do 50 godina

Izvor	Suma kvadrata	Stupnjevi slobode	Kvadratna sredina	F-vrijednost	p-vrijednost	
Blok	0,2575	4	0,0643			
<b>Model</b>	1,55	10	0,1548	146,33	< 0,0001	Značajan
A-Volumen	0,2795	2	0,1397	132,09	< 0,0001	
B-Masa	0,6489	1	0,6489	613,34	< 0,0001	
C-Visina police	0,0333	1	0,0333	31,50	< 0,0001	
AB	0,0275	2	0,0138	13,00	< 0,0001	
B <sup>2</sup>	0,0270	1	0,0270	25,48	< 0,0001	
C <sup>2</sup>	0,0806	1	0,0806	76,20	< 0,0001	
AB <sup>2</sup>	0,0174	2	0,0087	8,21	0,0003	
<b>Ostatak</b>	0,4570	432	0,0011			
Odstupanje	0,0241	30	0,0008	0,7468	0,8331	Nije značajno
Čista pogreška	0,4329	402	0,0011			
<b>Suma kvadrata odstupanja</b>	2,26	446				

Iz analize preklapanja po regresijskoj funkciji može se vidjeti dobro poklapanje skupa podataka i pripasane regresijske linije. Vidljivo je da je razlika između  $R^2$  skupa stvarnih podataka i modela manja od 0,02 te je u suštini zanemariva, što je još jedan pokazatelj ispravnosti modela.


**Tablica 6. Regresijska analiza modela za neoznačene kutije do 50 godina**

Standardna devijacija	0,0051	$R^2$	0,7683
Srednja vrijednost	1,03	$R^2$ korigirano	0,7629
Koeficijent varijance	0,4934	$R^2$ predviđeno	0,7517

**Tablica 7. Regresijska analiza modela za označene kutije do 50 godina**

Standardna devijacija	0,0325	$R^2$	0,7721
Srednja vrijednost	0,7274	$R^2$ korigirano	0,7668
Koeficijent varijance	4,47	$R^2$ predviđeno	0,7555

Nakon što se sakupljeni podaci aproksimiraju modelom, softver generira formule koje opisuju skup podataka.



**Slika 4. Opis skupa podataka funkcijom**

Formule se sastoje od faktorskih članova i koeficijenata te se razlikuju ovisno o skupini podataka. U nastavku su te iste formule navedene po veličini volumena, najprije za neoznačene, a zatim za označene kutije.

Neoznačene kutije malog volumena:

$$t = 1,0137 + 0,00976 * B - 0,00011 * C - 0,00121 * B^2 + 6,3908 * 10^{-7} * C^2 \quad (4.1)$$

Neoznačene kutije srednjeg volumena:

$$t = 1,0189 + 0,00516 * B - 0,00011 * C - 0,00030 * B^2 + 6,3908 * 10^{-7} * C^2 \quad (4.2)$$

Neoznačene kutije velikog volumena:

$$t = 1,0241 + 0,00348 * B - 0,00011 * C - 0,00016 * B^2 + 6,3908 * 10^{-7} * C^2 \quad (4.3)$$

Označene kutije malog volumena:

$$t = 0,8247 - 0,050 * B + 0,00079 * C + 0,00534 * B^2 - 4,6463 * 10^{-6} * C^2 \quad (4.4)$$

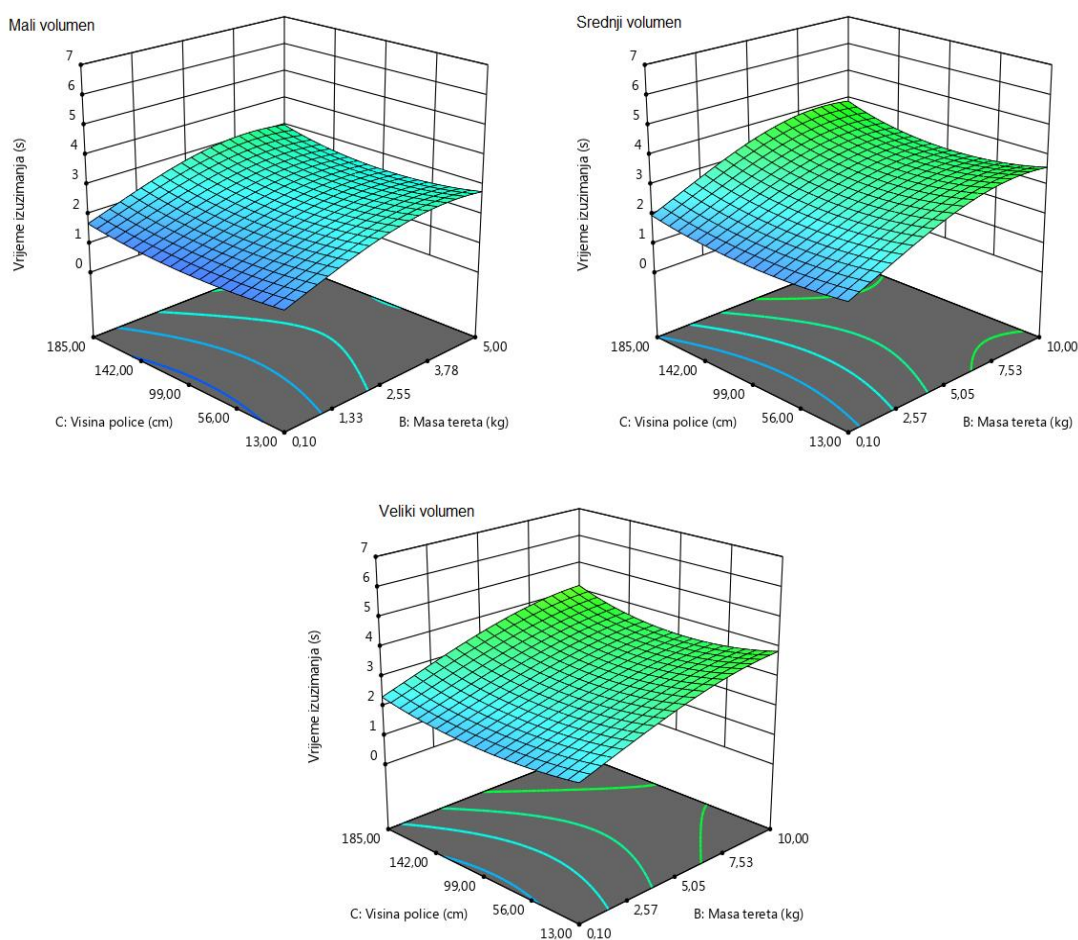
Označene kutije srednjeg volumena:

$$t = 0,75851 - 0,02485 * B + 0,00079 * C + 0,00133 * B^2 - 4,6463 * 10^{-6} * C^2 \quad (4.5)$$

Označene kutije velikog volumena:

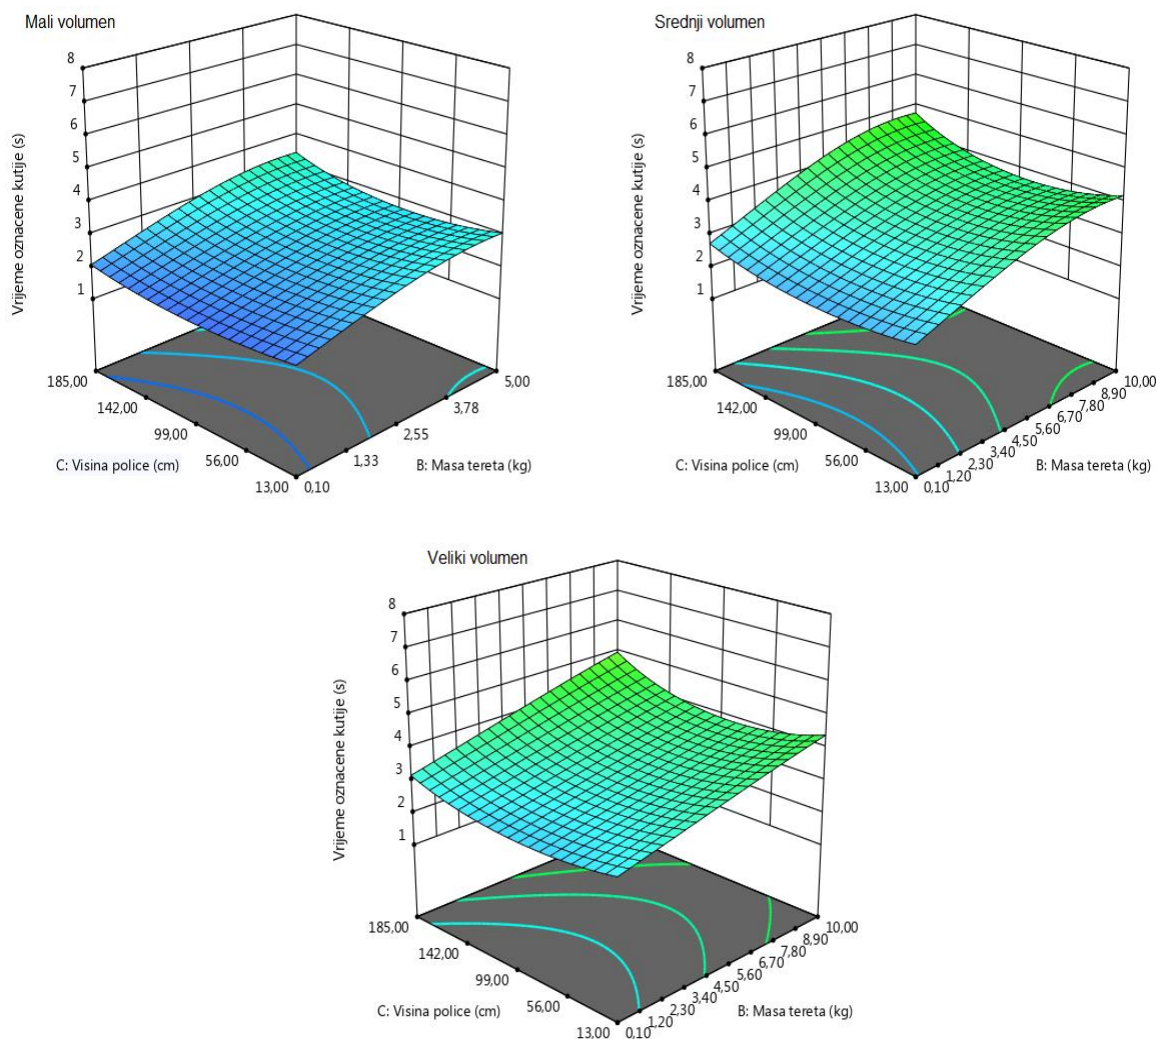
$$t = 0,75561 - 0,01235 * B + 0,00079 * C + 0,00033 * B^2 - 4,6463 * 10^{-6} * C^2 \quad (4.6)$$

Na sljedećim 3D prikazima mogu se vidjeti površine odziva koje su generirane iz gore navedenih matematičkih formula modela za vremena izuzimanja malih, srednjih i velikih kutija. Površine odziva na donjim prikazima odnose na neoznačene kutije i prikazane su kako bi se lakše razumjelo koji je krajnji rezultat matematičkih modela. 3D prikazi površina mogu se koristiti i za vizualnu usporedbu određenog područja odziva kod promatranih dobnih skupina, što slijedi u zadnjem dijelu rada.



**Slika 5. 3D površine neoznačenih kutija**

Iz 3-dimenzionalnih prikaza lako je uočiti porast vremena odziva s obzirom na volumen kutije, bez obzira na to koje je mase teret unutra [Slika 5.]. Logična je pretpostavka da budući da kod neoznačenih kutija ispitanicima nisu poznate mase kutija oni automatizmom pretpostavljaju da su veće kutije i teže, iako to nije uvijek slučaj. Također je lako uočiti porast utjecaj vremena s obzirom na utjecajne faktore, što je detaljnije elaborirano u nastavku.



**Slika 6. 3D površine označenih kutija**


#### 4.4. Analiza rasipanja

Analizom rasipanja usporedno će se gledati postoji li homogenost odziva te kako na to utječu pojedini parametri. Gledati će se rasipanje po razinama parametara, po samim parametrima i po označenosti i neoznačenosti. Posebnu pozornost treba obratiti na rasipanje s obzirom na masu kod označenih i neoznačenih kutija. Utjecaju označenosti valja pridati pozornost i kod analize rasipanja po razinama volumena zbog već spomenute pretpostavke da kada su kutije neoznačene ljudi automatizmom pretpostavljaju da veće kutije imaju i veću masu. Iz sljedećih prikaza može se uočiti jedna pravilnost kod ponašanja odziva: kada su na kutijama označene mase vremena izuzimanja čine unificiraniji skup nego kod neoznačenih kutija. Jedino u slučaju najviše police dolazi do još većeg rasipanja kod označenih kutija nego kod neoznačenih kutija, a za pretpostaviti je da je to zato što radnici još više uspore tempo rada kod visokih polica ako se radi o velikim masama, dok ako se radi o malim masama radnici su bili brži nego kod istih masa tereta kod neoznačenih kutija jer su sa sigurnošću znali da se ne radi o teretima velikih masa. Također, može se primijetiti da su vremena ukupno sporija kod označenih kutija nego kod neoznačenih, što daje zaključiti kako su ljudi u prosjeku više promišljali o brzini izuzimanja kada ih je oznaka mase na kutiji podsjetila na mogući napor prilikom samog izuzimanja, a što je posebno zanimljivo za primijetiti s obzirom na visinu police s koje se izuzima.

##### 4.4.1. Volumen

Kao prvi ulazni parametar korišten je volumen kutija. To je kategorički parametar određen u tri veličine bez mjerne jedinice: mali, srednji i veliki [Tablica 2.]. Analiza korelacije dobivena u softverskom programu pokazuje kako je zapravo nemoguće definirati korelaciju između veličine korelacije volumena i vremena odziva neoznačenih ili označenih kutija. Korelaciju nije moguće definirati upravo zato što se radi o kategoričkom parametru, no sama korelacija nije ključna za daljnju analizu i konačni cilj ovog rada te se njome ovaj rad neće podrobnije baviti. Iz donjeg prikaza [Slika 7.] može se vidjeti kako je skup odziva unificiraniji kod označenih kutija na svim razinama volumena, osim nekoliko odziva koji se mogu smatrati nereprezentativni.






**Slika 7. Rasipanje odziva s obzirom na volumen**

#### 4.4.2. Masa tereta


Drugi ulazni parametar je masa tereta klasificirana u pet razreda: 0,1 kg, 1 kg, 5 kg i 10 kg. Nedvojbeno je da masa tereta utječe na vrijeme izuzimanja kutija iz regala, što analiza u Design Expertu potvrđuje. Iskazuje se korelacija između mase tereta i vremena izuzimanja neoznačenih kutija od 0,8 te mase tereta i vremena izuzimanja označenih kutija od 0,75. Iz priloženih slika vidi se veće rasipanje kod kutija s označenom masom [Slika 8.], a pogotovo kod teških kutija od 10 kg, gdje je za pretpostaviti da su radnici vidjevši da se radi o kutijama velike mase prilagodili tempo rada vlastitim ergonomskim mogućnostima s ciljem odrađivanja zadanog izuzimanja sa što manjim naporom.



**Slika 8. Rasipanje odziva s obzirom na masu tereta**

#### 4.4.3. Visina police

Kao treći relevantni parametar gleda se visina police. Pretpostavka je da nepogodna visina police u kombinaciji s većim masama tereta uvelike doprinosi produljenju vremena izuzimanja. Što se tiče utjecaja na homogenost podataka vidi se da visina police djeluje nepogodnije na homogenost podataka od volumena i mase tereta. Kao što je već spomenuto, parametar je klasificiran u 5 razreda prema visinama polica: 13 cm, 56 cm, 100 cm, 143 cm, i 185 cm. Programska analiza je pokazala da postoji korelacija između visine police i vremena izuzimanja neoznačenih kutija od 0,081 odnosno između visine police i vremena izuzimanja označenih kutija od 0,148.



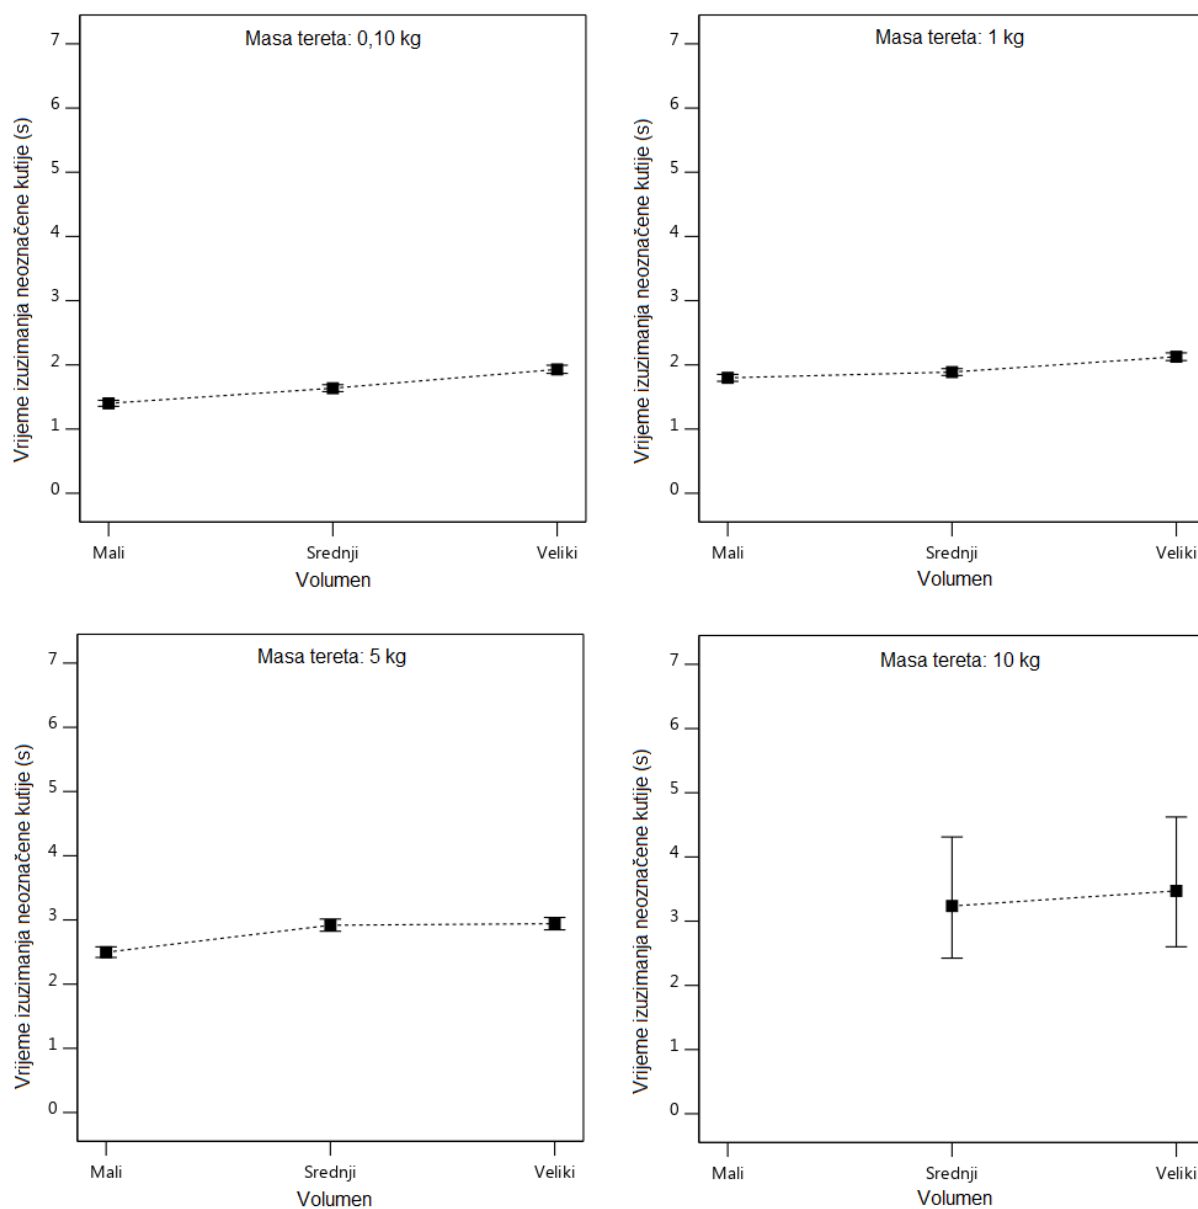
**Slika 9. Rasipanje tereta s obzirom na visinu police**

#### **4.5. Analiza odziva po faktorima**

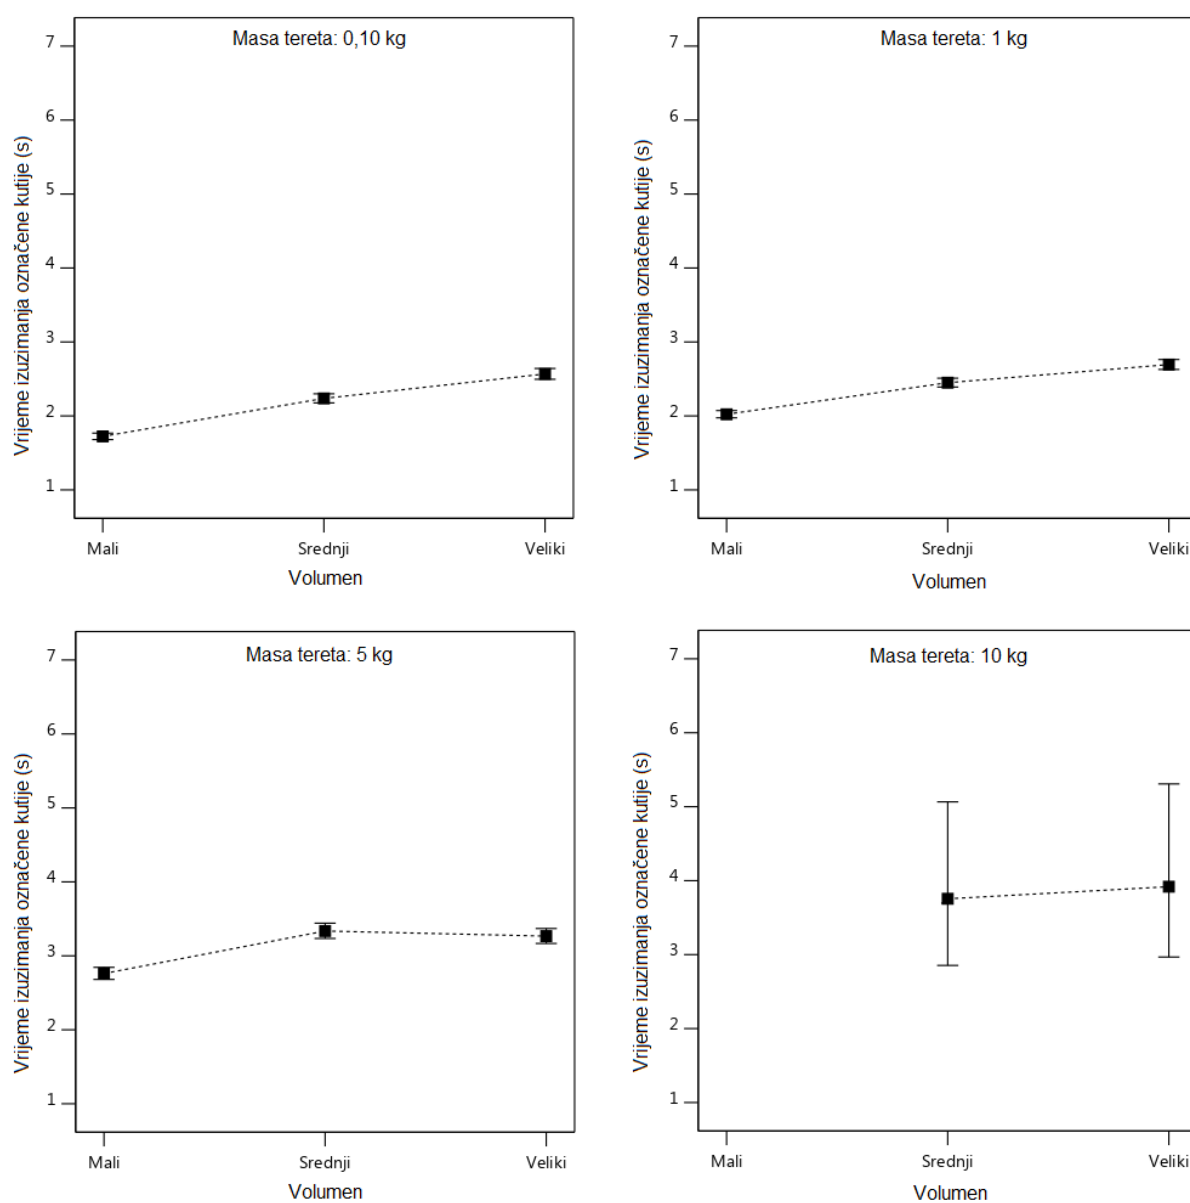
Sljedeća cjelina bavi se prikazom promjene vremena odziva s promjenom veličine jednog faktora u ovisnosti o veličinama drugih utjecajnih faktora. Objašnjava se kako promjena utjecajnih faktora utječe na ponašanje odziva. Također se promatra i razlika odziva kod neoznačenih i označenih kutija.

##### **4.5.1. Utjecaj mase na vrijeme odziva za skupinu do 50 godina**

Logično je zaključiti da s porastom mase tereta raste i vrijeme odziva. No također, prilikom ove analize, htjelo se vidjeti kakav utjecaj volumen kutije ima na vrijeme odziva s obzirom na masu tereta u kutiji. Točnije, htjelo se vidjeti kako radnici percipiraju masu volumena, pogotovo ako je ona neoznačena, s obzirom na to radi li se o maloj srednjoj ili velikoj kutiji tereta. Kod kutija koje nemaju označenu masu [Slika 10.] vidljivo je kako se bez obzira na konstantnu masu događa porast vremena izuzimanja. Na primjer, ako je masa tereta 0,10 kg, i dalje će biti potrebno više vremena da se izuzme kutija velikog volumena nego malog ili srednjeg. Dakle, evidentno je da s obzirom da ne znaju kolika je masa tereta radnici automatizmom pretpostavljaju da su velike kutije teže. Kod kutija s označenom masom tereta vidljiv je blagi porast vremena izuzimanja u prosjeku [Slika 11.]. Porast je najočitiji kod kutija srednje veličine, a to se može pripisati tome da su i kutije srednjih volumena imale mase od 5 i 10 kg, što možda radnici nisu očekivali prilikom izuzimanja neoznačenih kutija. Zanimljivo je primijetiti da kod mase tereta od 5 kg kada je masa označena razlika između srednjeg i velikog volumena je zanemariva. Generalna sličnost izgleda grafova po razredima mase tereta ide u prilog analizi korelacije iz koje je zaključeno da korelaciju između veličine volumena nije moguće definirati. Valja napomenuti da je prilikom ove usporedbe parametar visine uzet kao prosječna vrijednost svih unosa visine police od 98,83 cm.




**Slika 10. Utjecaj mase kod neoznačenih kutija za skupinu do 50 godina**




Slika 11. Utjecaj mase kod označenih kutija za skupinu do 50 godina

#### 4.5.2. Utjecaj visine na vrijeme odziva za skupinu do 50 godina

U sljedećim grafovima prikazano je vrijeme odziva po razinama faktora mase s obzirom na visinu police. Iz grafova se vidi kako je najkraće vrijeme izuzimanja na visini police od 100 centimetara, što je i za očekivati s obzirom da je to ergonomski najpovoljnija od svih visina polica na ovom regalu. Također, jasno je da s obzirom na masu najkraće je vrijeme odziva kod tereta mase 0,10 kilograma. Iz prikazanih grafova dalo bi se naslutiti da su tereti masa 10 kilograma u prosjeku vrže izuzimani od tereta 5 kilograma, što se možda čini kontradiktornim, ali se da objasniti velikim rasipanjem. Za sve je razrede mase karakteristično da su vremena ekstrema visina bila u prilog najnižoj polici, to jest vrijeme izuzimanja je trajalo u prosjeku kraće kada se izuzimalo s najniže police od vremena izuzimanja s najviše police.



**Slika 12. Utjecaj visine police kod neoznačenih kutija za skupinu do 50 godina**

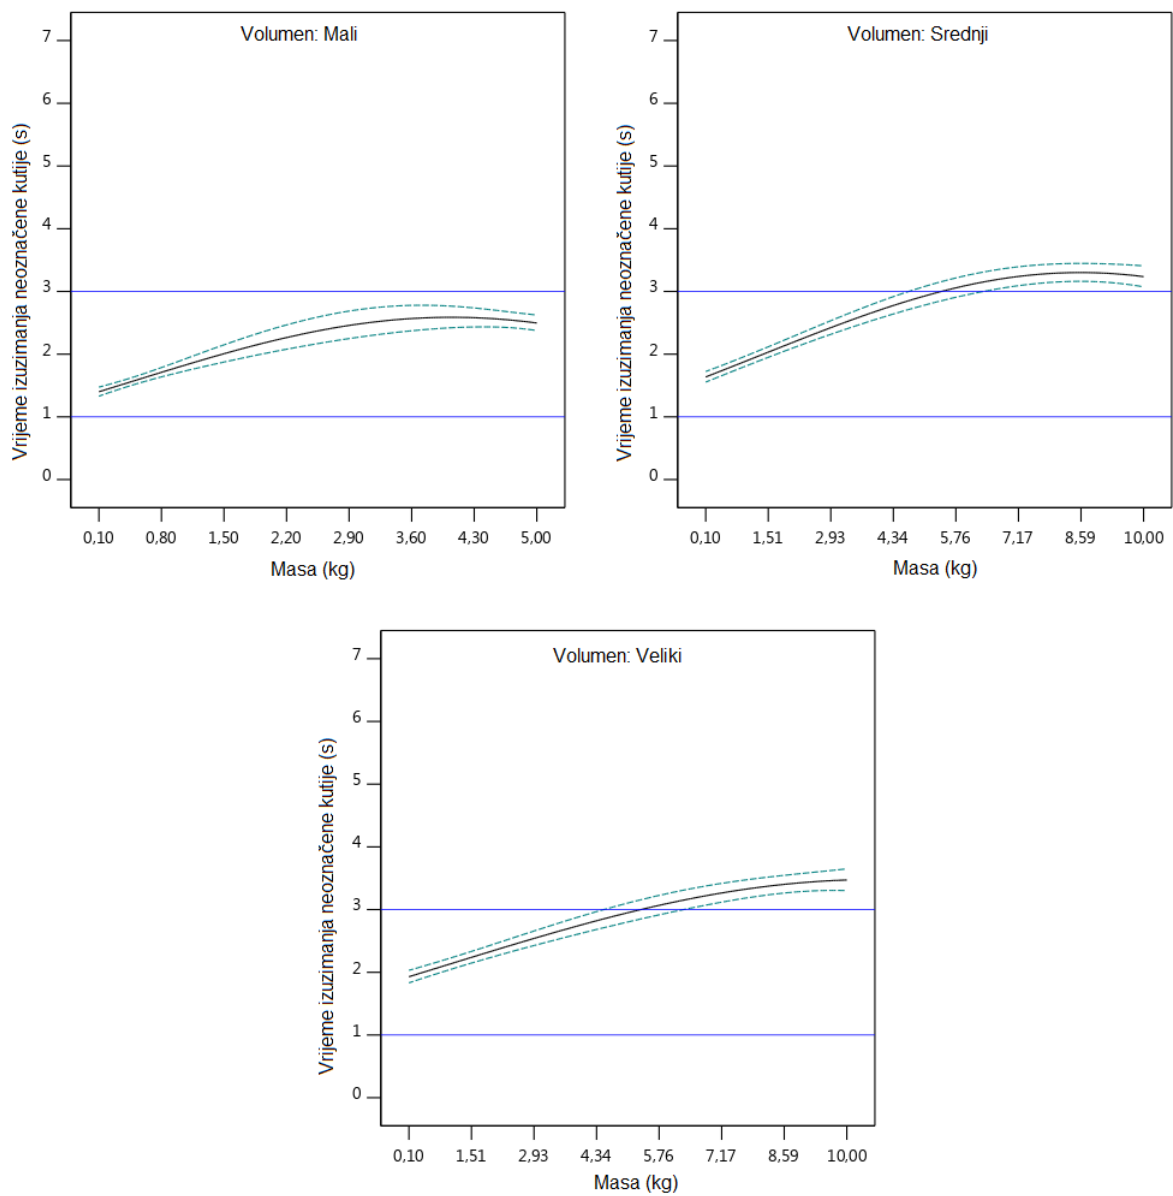


**Slika 13.** Utjecaj visine police kod označenih kutija za skupinu do 50 godina


**4.5.3. Utjecaj volumena na vrijeme odziva za skupinu do 50 godina**

Utjecaj volumena na vrijeme odziva izraženiji je kod neoznačenih kutija, još jednom zbog toga što ljudi automatizmom pretpostavljaju da veće kutije imaju veće mase. Tako je vidljivo da s porastom volumena prosječna vremena rastu po svim masama, a također s porastom mase, očekivano događa se i porast vremena po razini volumena. Gledano usporedno za označene i neoznačene kutije ne može se primijetiti velika razlika, osim kod srednjih volumena gdje kod označenih kutija prosječna vremena nastavljaju s rastom dok se kod neoznačenih volumena ustaljuju, što se opet može pripisati tome da su radnici bili svjesniji velike mase u srednjem volumenu kada je ona bila označena.





**Slika 14. Utjecaj volumena kod neoznačenih kutija za skupinu do 50 godina**



**Slika 15.** Utjecaj volumena kod označenih kutija za skupinu do 50 godina

## 5. ANALIZA PODATAKA ZA SKUPINU 50 I VIŠE GODINA

### 5.1. Sakupljeni podaci

Prilikom provedbe pokusa sa skupinom ispitanika od 50 godina i više podaci su sakupljeni na isti način, a pazilo se i da laboratorijski uvjeti budu isti kao i kod skupine ispitanika manje od 50 godina starosti. Informacije o prikupljenim podacima prikazane su u sljedećoj tablici, podijeljene na neoznačene i označene kutije.

**Tablica 8. Sakupljeni podaci za skupinu 50 i više godina**

Kutije	Jedinica	Veličina uzorka	Min	Max	Srednja vrijednost	Standardna devijacija
Neoznačene	s	266	1,04	7,56	2,81	1,19
Označene	s	266	1,04	7,00	2,75	1,12

Iz tablice 8 vidi se kako je uzorak nešto manji nego kod skupine ispitanika mlađih od 50 godina, no primjenom ispravnog modela ta razlika gubi na značajnosti. Zanimljivo je da je kod skupine od 50 i više godina srednje vrijeme označenih kutija manje nego neoznačenih dok je kod skupine ispitanika mlađih od 50 godina stanje obratno. Ovakav rezultat mogao bi se pripisati većem oprezu starijih ispitanika kod neoznačenih kutija.

### 5.2. Korelacija parametara i odziva

Kao i kod prethodne skupine podataka, u programskom paketu Design Expert 11 moguć je uvid u korelaciju pojedinog parametra i vremena odziva u matričnom prikazu [Slika 3.], a odabirom pojedinog polja vidljiv je grafički prikaz korelacije.

### 5.3. Model za skupinu 50 i više godina

Isto kao i za skupinu podataka dobivenih iz mjerenja vremena izuzimanja kod ispitanika do 50 godina, podaci su aproksimirani kvadratnim modelom s interakcijama. Članovi i faktori također su navedeni u drugom dijelu ovog potpoglavlja. Najprije slijedi analiza varijance kojom se gleda prikladnost modela iz koje se vidi prikladnost modela za ove skupove podataka.

Tablica 9. Analiza varijance za neoznačene kutije za 50 i više godina

Izvor	Suma kvadrata	Stupnjevi slobode	Kvadratna sredina	F-vrijednost	p-vrijednost	
<b>Model</b>	1,66	8	0,2078	96,65	< 0,0001	Značajan
A-Volumen	0,3981	2	0,1990	92,58	< 0,0001	
B-Masa	0,5573	1	0,5573	259,22	< 0,0001	
C-Visina police	0,1144	1	0,1144	53,22	< 0,0001	
AB	0,0393	2	0,0196	9,14	0,0001	
B <sup>2</sup>	0,0267	1	0,0267	12,41	0,0005	
C <sup>2</sup>	0,1321	1	0,1321	61,43	< 0,0001	
<b>Ostatak</b>	0,5525	257	0,0021			
Odstupanje	0,0888	36	0,0025	1,18	0,2395	Nije značajno
Čista pogreška	0,4637	221	0,0021			
<b>Suma kvadrata odstupanja</b>	2,21	265				

Tablica 10. Analiza varijance za označene kutije za 50 i više godina

Izvor	Suma kvadrata	Stupnjevi slobode	Kvadratna sredina	F-vrijednost	p-vrijednost	
<b>Model</b>	1,72	8	0,2147	75,93	< 0,0001	Značajan
A-Volumen	0,1834	2	0,0917	32,43	< 0,0001	
B-Masa	0,9152	1	0,9152	323,64	< 0,0001	
C-Visina police	0,1068	1	0,1068	37,78	< 0,0001	
BC	0,0139	1	0,0139	4,90	0,0278	
B <sup>2</sup>	0,0332	1	0,0332	11,75	0,0007	
C <sup>2</sup>	0,1630	1	0,1630	57,64	< 0,0001	
<b>Ostatak</b>	0,7268	257	0,0028			
Odstupanje	0,1339	36	0,0037	1,39	0,0816	Nije značajno
Čista pogreška	0,5929	221	0,0027			
<b>Suma kvadrata odstupanja</b>	2,44	265				

Iz regresijske analize može se vidjeti dobro poklapanje skupa podataka i pripasane regresijske linije. Razlika između  $R^2$  Skupa stvarnih podataka i modela manja je od 0,02, što pokazuje ispravnost modela.


**Tablica 11. Regresijska analiza modela za neoznačene kutije za 50 i više godina**

Standardna devijacija	0,0464	$R^2$	0,7505
Srednja vrijednost	0,7571	$R^2$ korigirano	0,7428
Koeficijent varijance	6,12	$R^2$ predviđeno	0,7332

**Tablica 12. Regresijska analiza modela za označene kutije za 50 i više godina**

Standardna devijacija	0,0532	$R^2$	0,7027
Srednja vrijednost	1,21	$R^2$ korigirano	0,6934
Koeficijent varijance	4,40	$R^2$ predviđeno	0,6810

Softverski paket generira formule koje opisuju skup podataka, a aproksimacija skupa podataka izgleda kao na sljedećim prikazima.



**Slika 16. Opis skupa podataka za skupinu 50 i više godina**

U nastavku su navedene formule koje opisuju skup podataka za skupinu ispitanika od 50 i više godina. Formule navedene po veličini volumena, najprije za neoznačene, a zatim za označene kutije.

Neoznačene kutije malog volumena:

$$t = 0,8776 - 0,03174 * B + 0,00109 * C + 0,00107 * B^2 - 7,2373 * 10^{-6} * C^2 \quad (5.1)$$

Neoznačene kutije srednjeg volumena:

$$t = 0,7986 - 0,02375 * B + 0,00109 * C + 0,00107 * B^2 - 7,2373 * 10^{-6} * C^2 \quad (5.2)$$

Neoznačene kutije velikog volumena:

$$t = 0,7474 - 0,01966 * B + 0,00109 * C + 0,00107 * B^2 - 7,2373 * 10^{-6} * C^2 \quad (5.3)$$

Označene kutije malog volumena:

$$t = 1,1166 + 0,02652 * B - 0,00092 * C - 0,00009 * B * C - 0,00103 * B^2 + 5,7434 * 10^{-6} * C^2 + 5,8832 * 10^{-7} * B * C^2 \quad (5.4)$$

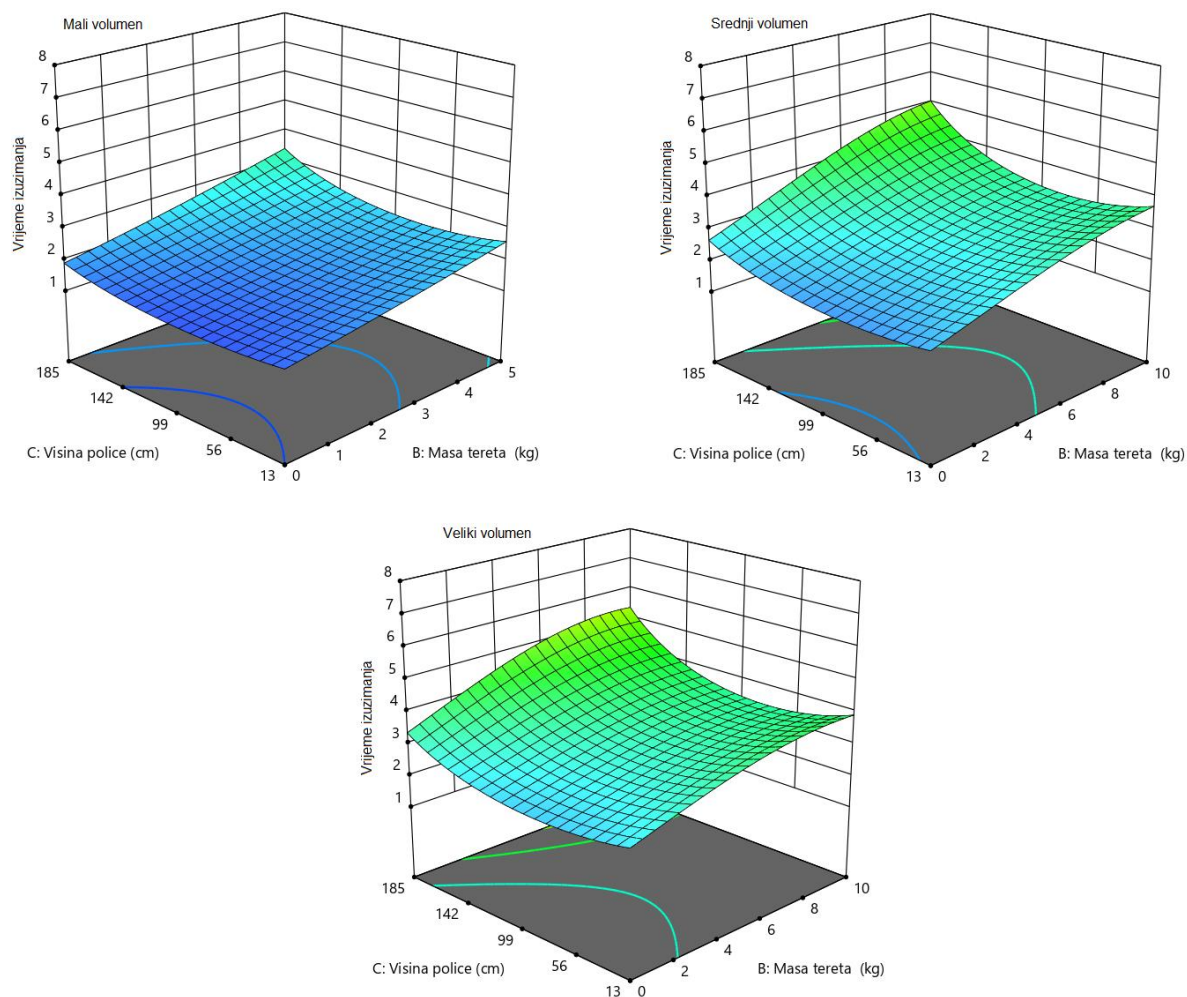
Označene kutije srednjeg volumena:

$$t = 1,1516 + 0,02652 * B - 0,00092 * C - 0,00009 * B * C - 0,00103 * B^2 + 5,7434 * 10^{-6} * C^2 + 5,8832 * 10^{-7} * B * C^2 \quad (5.5)$$

Označene kutije velikog volumena:

$$t = 1,1854 + 0,02652 * B - 0,00092 * C - 0,00009 * B * C - 0,00103 * B^2 + 5,7434 * 10^{-6} * C^2 + 5,8832 * 10^{-7} * B * C^2 \quad (5.6)$$

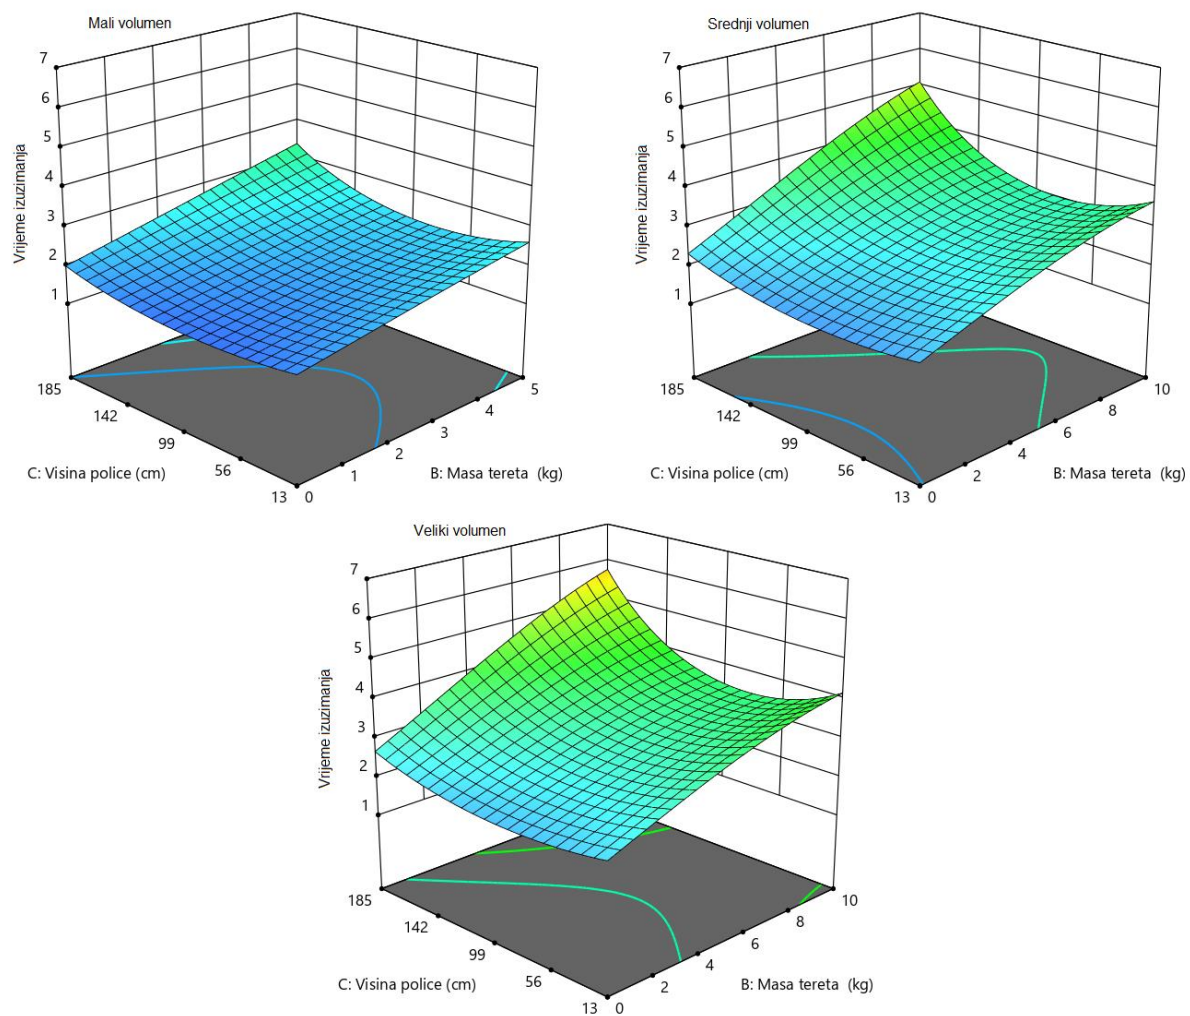
Na sljedećim slikama prikazane su 3D površine odziva koje su generirane iz gore navedenih matematičkih formula modela za vremena izuzimanja malih, srednjih i velikih kutija.



**Slika 17. 3D površine neoznačenih kutija kod skupine 50 i više godina**

Iz ovih prikaza lako je uočljiv ukupni porast vremena s obzirom na razrede volumena, kao i kod druge dobne skupine.






**Slika 18. 3D površine označenih kutija kod skupine 50 i više godina**

## 5.4. Analiza rasipanja

Kao i za prethodnu dobnu skupinu, kod analize rasipanja gledati će se homogenost odziva i utjecaj parametara na homogenost. Isto tako je potrebno posebno obratiti pozornost na rasipanje s obzirom na masu kod označenih i neoznačenih kutija.

### 5.4.1. Volumen


Volumen je kategorički određen u tri veličine bez mjerne jedinice: mali, srednji i veliki [Tablica 2.]. Isto kao i kod druge dobne skupine, korelacija je nedefinirana upravo zato što se radi o kategoričkom parametru.



**Slika 19. Rasipanje odziva s obzirom na volumen za 50 i više godina**

### 5.4.2. Masa tereta


Iskazuje se korelacija između mase tereta i vremena izuzimanja neoznačenih kutija u iznosu od 0,516 dok je korelacija između mase tereta i vremena izuzimanja označenih kutija 0,614 [Slika 20.].



**Slika 20. Rasipanje odziva s obzirom na masu za 50 i više godina**

#### 5.4.3. Visina police

Kao i kod prethodne dobne skupine, pretpostavka je da nepogodna visina police u kombinaciji s većim masama tereta doprinosi produljenju vremena izuzimanja. Programska analiza pokazala je korelaciju između visine police i vremena izuzimanja neoznačenih kutija od 0,225, odnosno 0,206 za označene kutije.



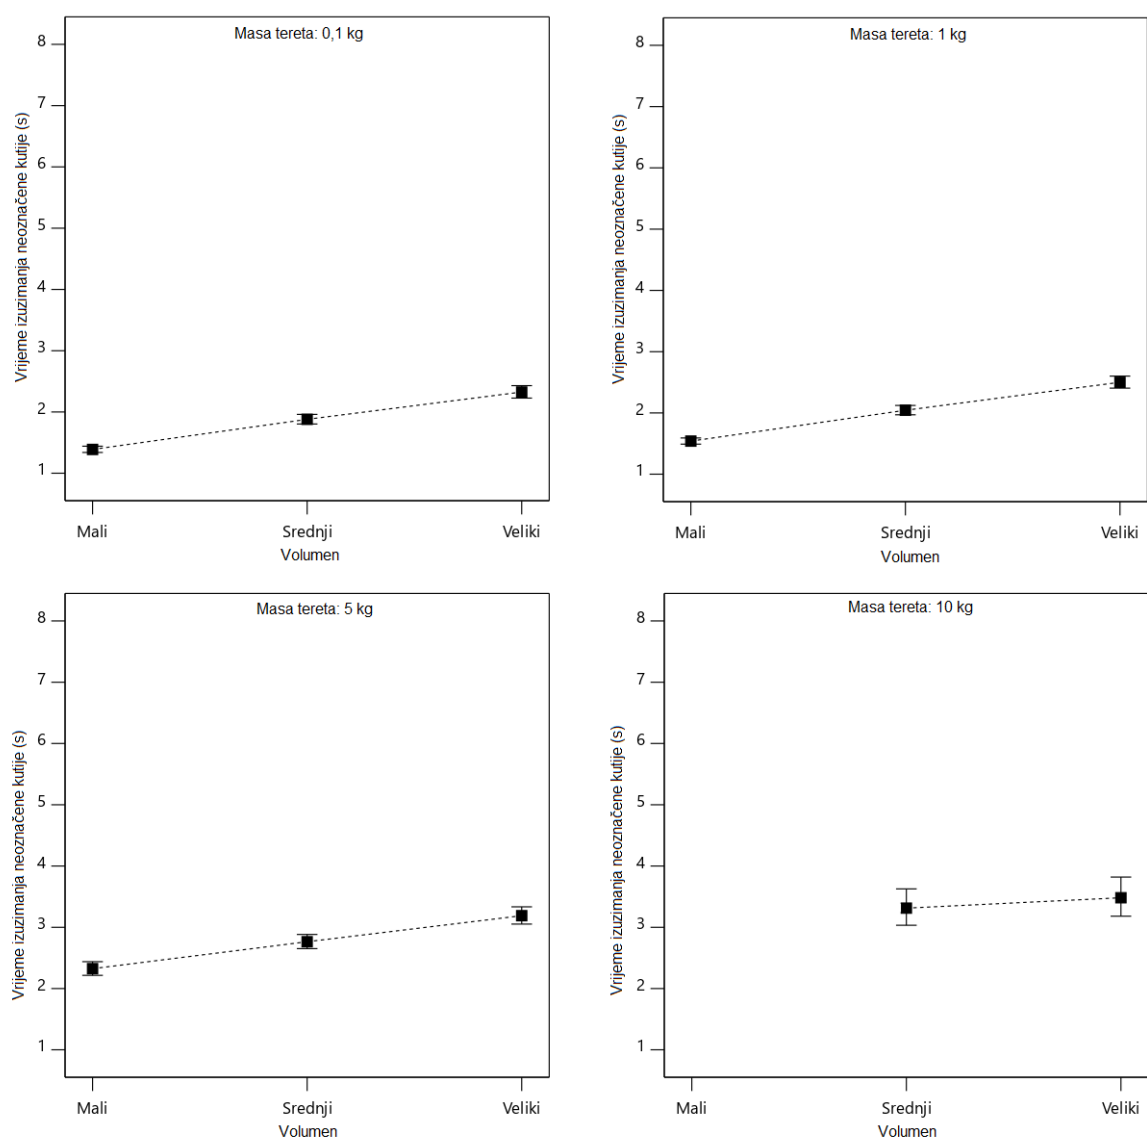
**Slika 21. Rasipanje odziva s obzirom na visinu police za 50 i više godina**

## **5.5. Analiza odziva po faktorima**

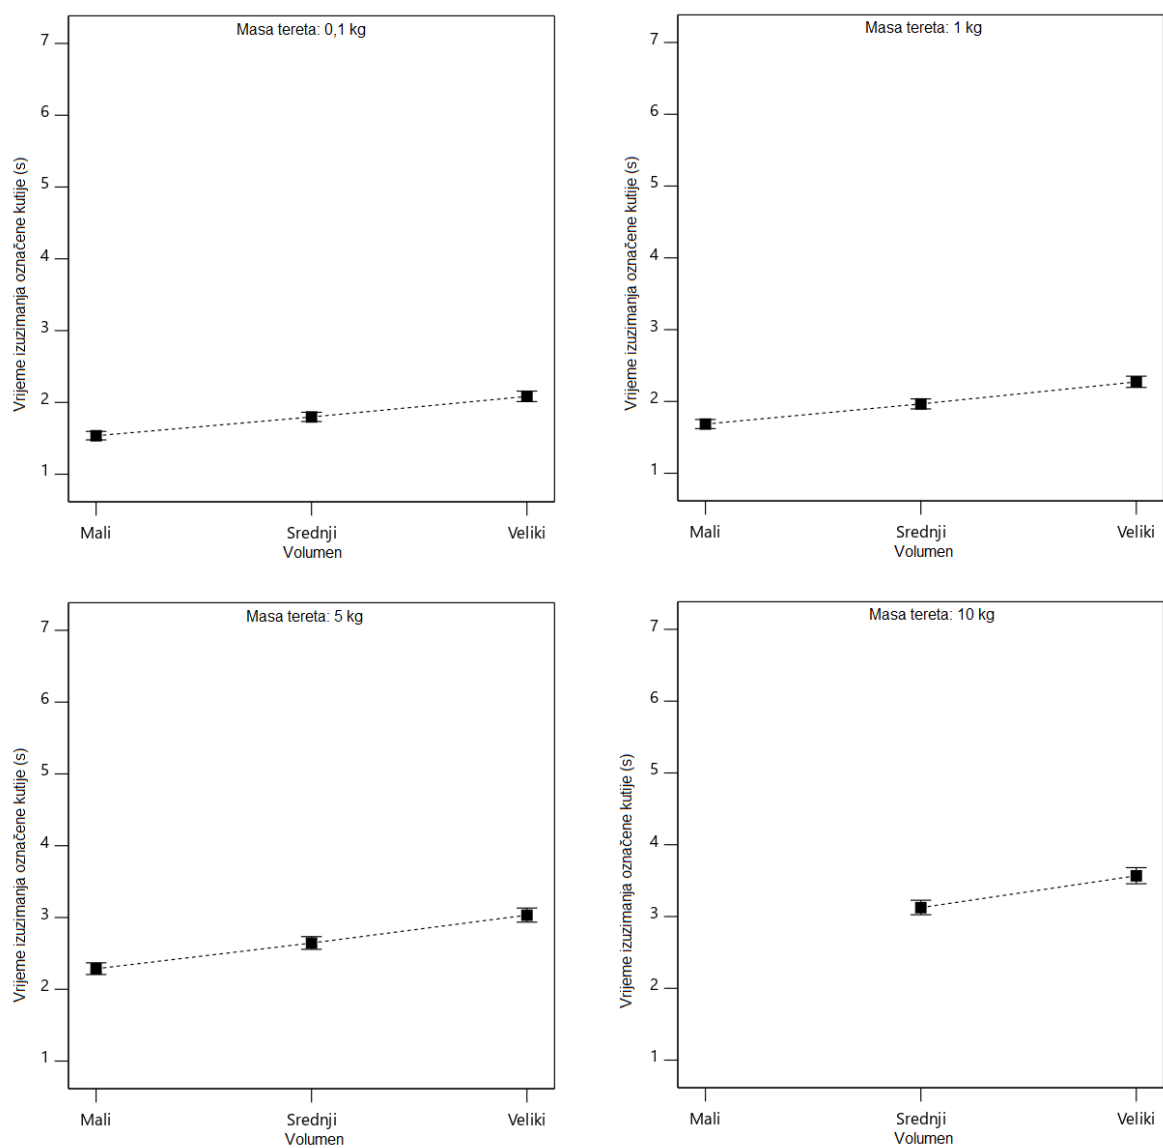
Kao i za prethodnu dobnu skupinu, objašnjava se kako promjena utjecajnih faktora utječe na ponašanje odziva, uz istovremeno promatranje razlike odziva kod neoznačenih i označenih kutija.

### **5.5.1. Utjecaj mase na vrijeme odziva za skupinu 50 i više godina**

Kod dobne skupine od 50 i više godina pojavljuje se isti učinak koji je viđen i kod druge dobne skupine, samo je on izraženiji. Naime, s porastom volumena kutija raste i vrijeme izuzimanja kutije bez obzira što se radi o istoj masi tereta. Dok je ovaj učinak volumena kod dobne skupine mlađih od 50 godina bio izražen samo kod masa tereta 0,1 i 1 kilogram, kod ove dobne skupine on je vidljiv kod svih razina mase tereta i prisutan je i kod neoznačenih, ali i kod označenih kutija.




**Slika 22. Utjecaj mase kod neoznačenih kutija za skupinu 50 i više godina**



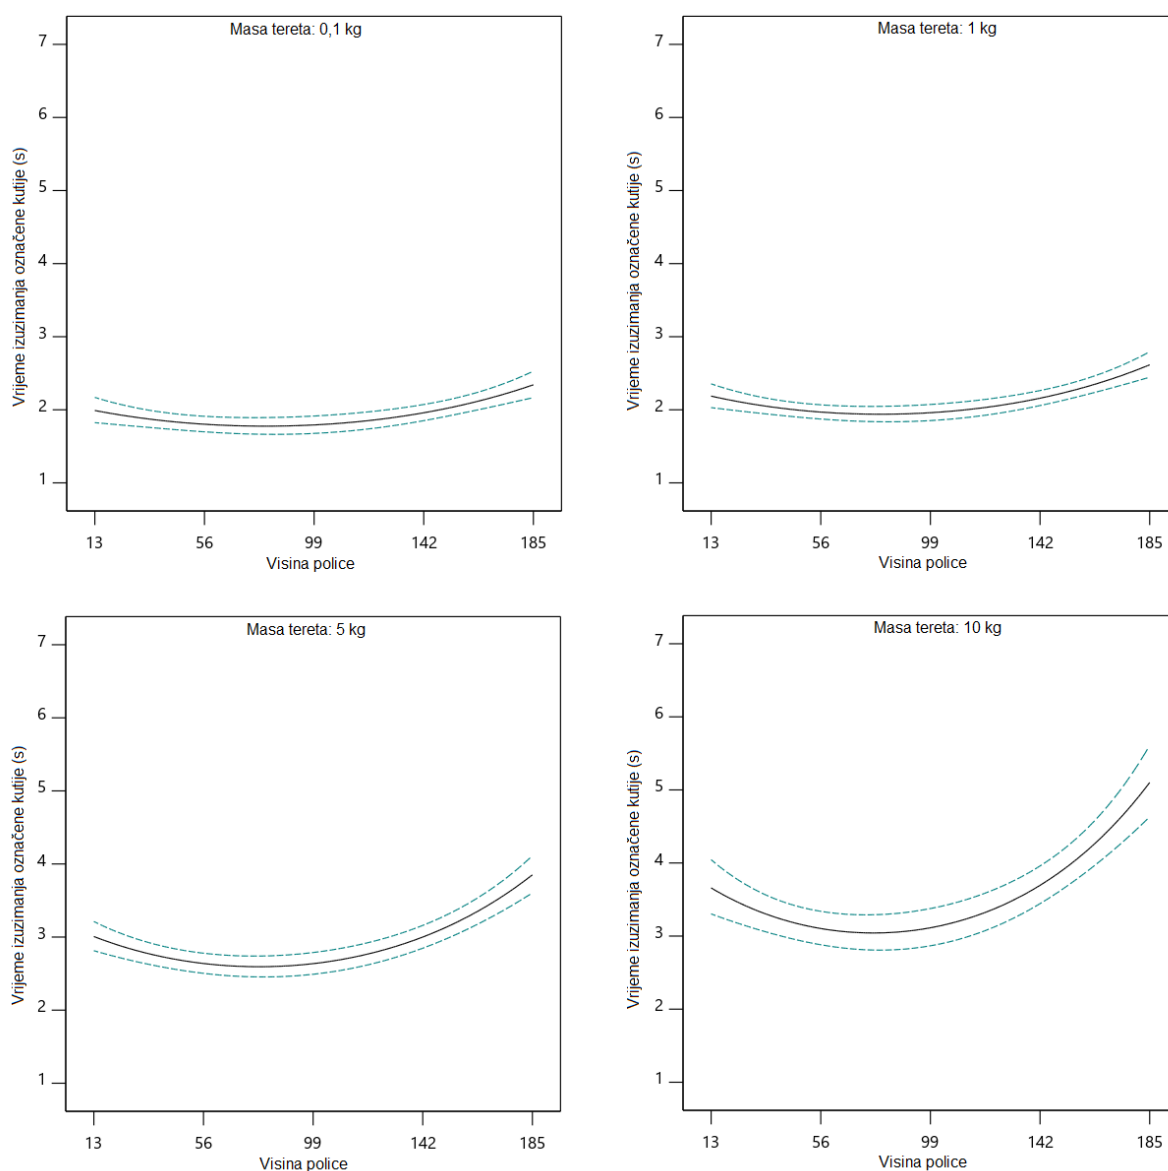
Slika 23. Utjecaj mase kod označenih kutija za skupinu 50 i više godina

### 5.5.2. Utjecaj visine na vrijeme odziva za skupinu 50 i više godina

Vrijeme odziva po razinama faktora mase s obzirom na visinu police vidljivo u sljedećim prikazima pokazuje da je razlika s obzirom na visinu puno izraženija kod dobne skupine od 50 i više godina. Jasnije je vidljivo kako su ekstremi faktora visine, odnosno najniža i najviša polica kod mase tereta od 5 i 10 kilograma, utjecali negativno na vrijeme izuzimanja. Krivulja odziva je puno izraženija zato što dok ergonomski prihvatljiva srednja visina od 100 cm starijoj dobnoj skupini ne predstavlja problem, kod nižih polica koje zahtijevaju sagibanje, vrijeme izuzimanja se drastično produžuje. Kod najviše police vrijeme izuzimanja je još duže zato što osim ergonomske nepovoljnosti, treba računati i na to da su radnici oprezniji kada izuzimaju s visine.



**Slika 24. Utjecaj visine police kod neoznačenih kutija za skupinu od 50 i više godina**

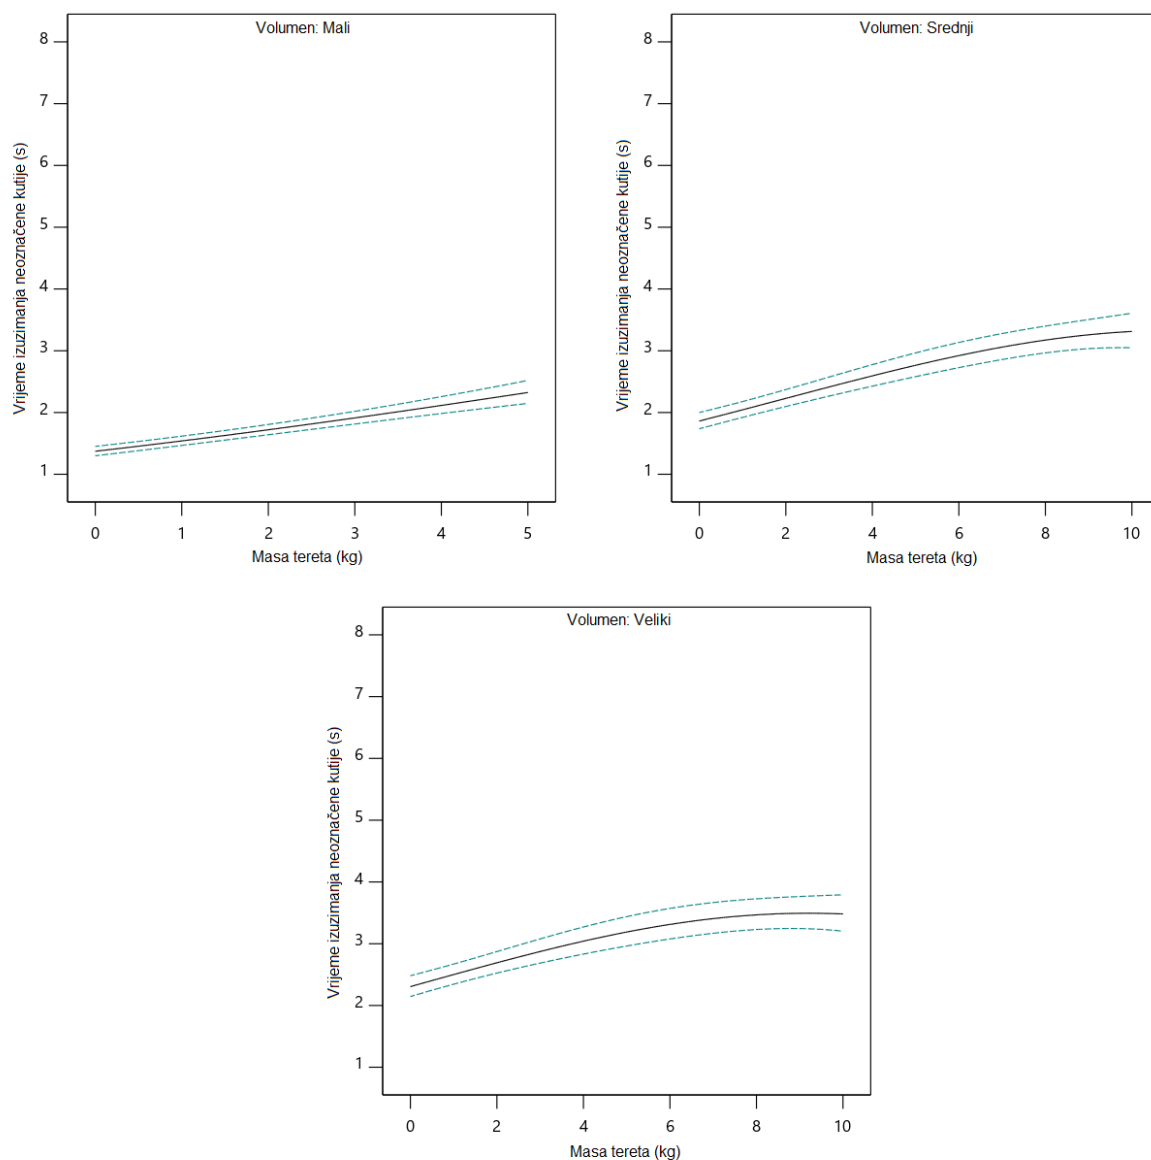


**Slika 25.** Utjecaj visine police kod označenih kutija za skupinu od 50 i više godina

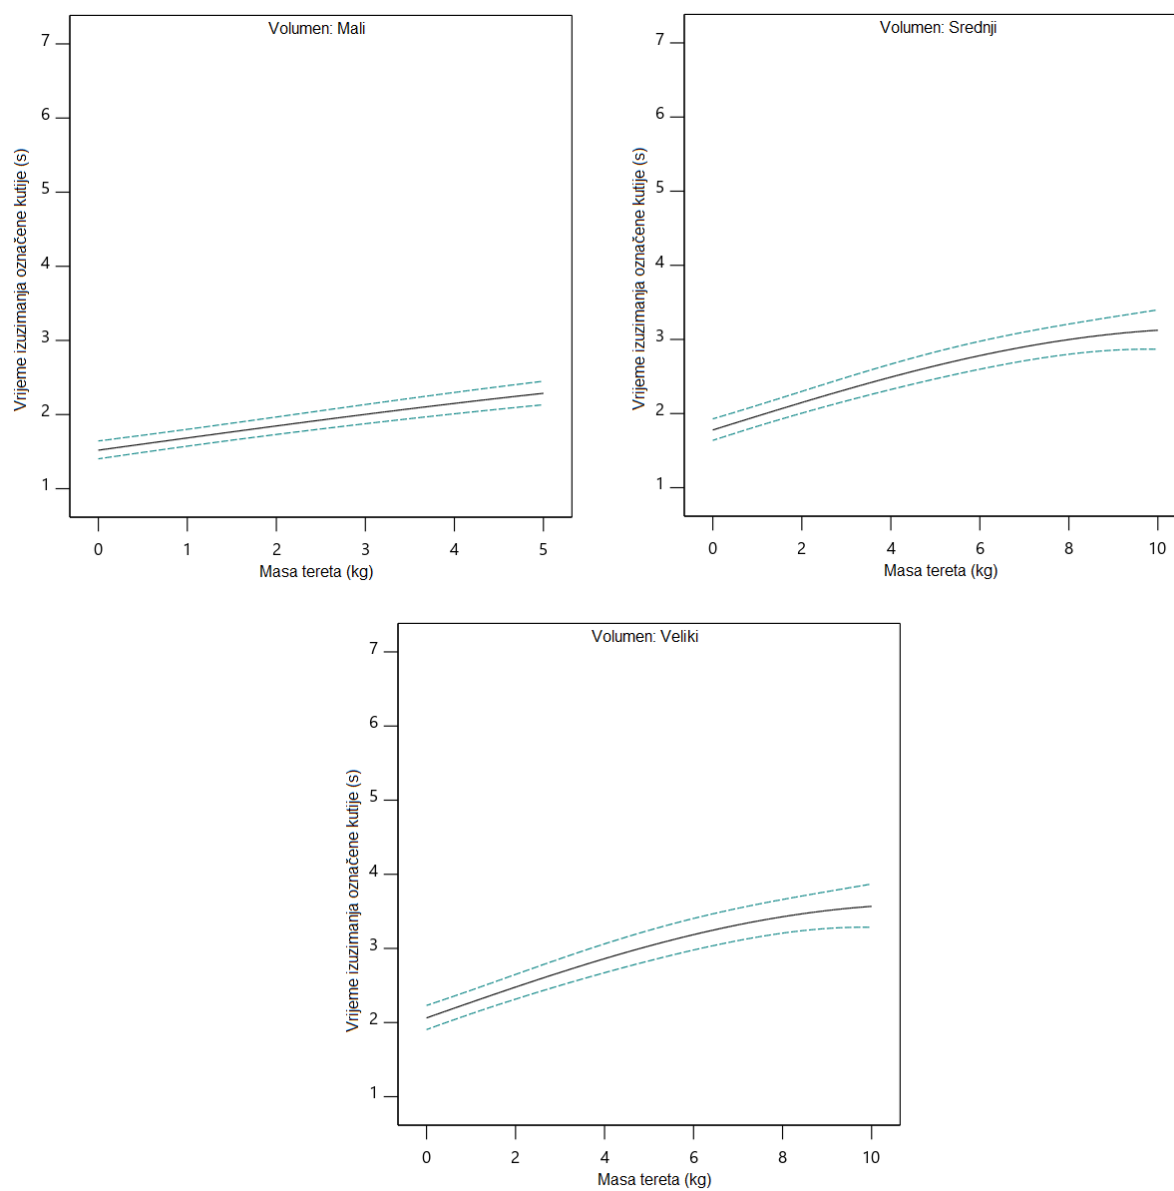


### 5.5.3. Utjecaj volumena na vrijeme odziva za skupinu od 50 i više godina

Kao i kod druge dobne skupine, utjecaj volumena na vrijeme izuzimanja izraženiji je kod neoznačenih kutija, isto tako zato što ljudi automatizmom pretpostavljaju da veće kutije imaju veće mase. Zanimljivo je vidjeti kako je porast vremena izuzimanja između razreda masa 5 i 10 kilograma kod neoznačenih kutija manji nego kod označenih kutija. Iz toga se da vidjeti da su ispitanici iz ove dobne skupine obraćali pozornost na oznake mase i više pripazili na tempo rada i ergonomiju samog izuzimanja kod kutija na kojima su bile naznačene velike mase.



**Slika 26.** Utjecaj volumena kod neoznačenih kutija za skupinu od 50 i više godina




**Slika 27.** Utjecaj volumena kod označenih kutija za skupinu od 50 i više godina

## 6. USPOREDBA DOBNIH SKUPINA

Nakon provedene analize podataka, a poglavito analize utjecaja faktora na odziv, treba usporediti podatke među dobnim skupinama. Ranije je spomenuto kako su prilikom provođenja pokusa ispitanici podijeljeni u dvije dobne skupine: ispitanici do 50 godina starosti i ispitanici s više od 50 godina. Usporedba se provodi analizom varijance među dobnim skupinama. Za potrebe analize korišten je program „Statistica“ gdje su podaci uneseni prema istim ranije spomenutim utjecajnim faktorima i prema dobnim skupinama. Analiza je provedena samo za neoznačene kutije zato što se smatra da bi takvi bili realni uvjeti. Prilikom provođenja analize varijance važno je gledati vrijednost  $p$ , pri čemu vrijedi pravilo da ako je  $p < 0,05$  postoji značajna razlika između vremena izuzimanja dobnih skupina jer se nulta hipoteza odbacuje. Nulta hipoteza govori da ne postoji značajna razlika između vremena odziva dviju dobnih skupina.

### 6.1. Usporedba s obzirom na visinu police

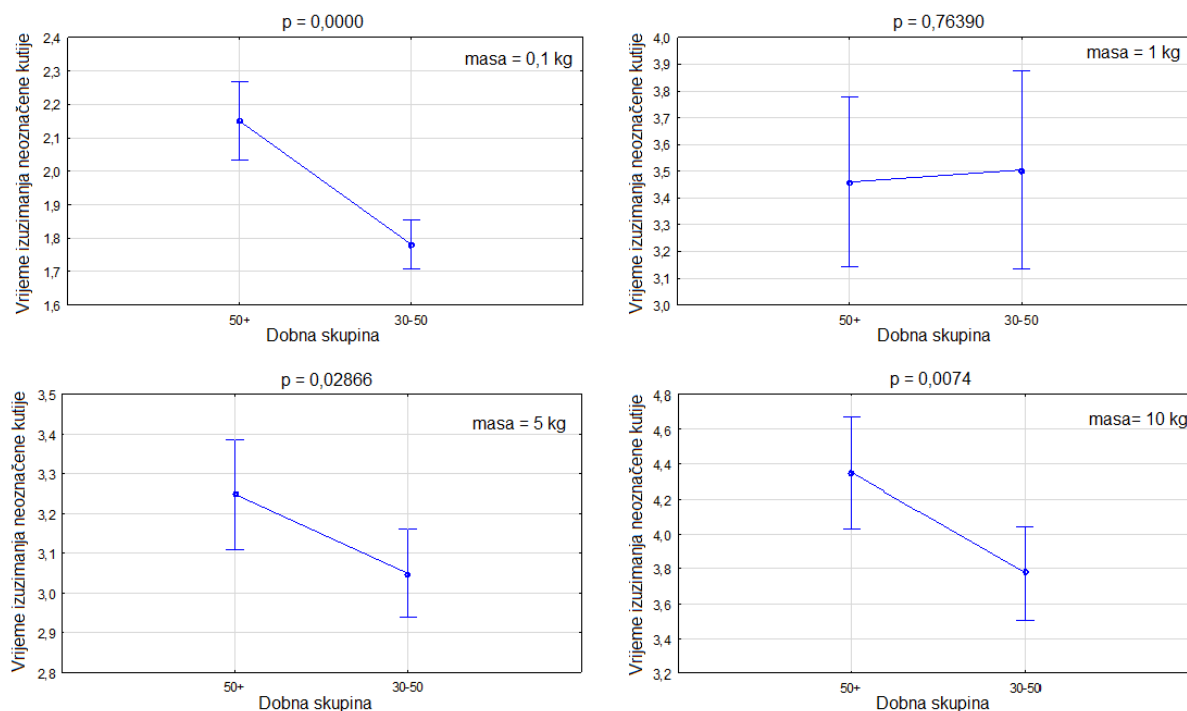
Prema grafovima generiranim u softverskom paketu „Statistica“ možemo vidjeti da značajna razlika između dobnih skupina, gledano prema faktoru visina police, postoji samo kod izuzimanja kutija sa najviše police. U tome su slučaju ispitanici iz mlađe dobne skupine znatno brži te se u prikazu „box & whiskers“ niti vrijednosti whiskera ne preklapaju [Slika 28.]. Značajnost razlike potvrđuje i vrijednost  $p = 0,00085$  za visinu police 185 centimetara.



**Slika 28. Analiza varijance dobnih skupina kategorizirano po visini**

## 6.2. Usporedba s obzirom na masu

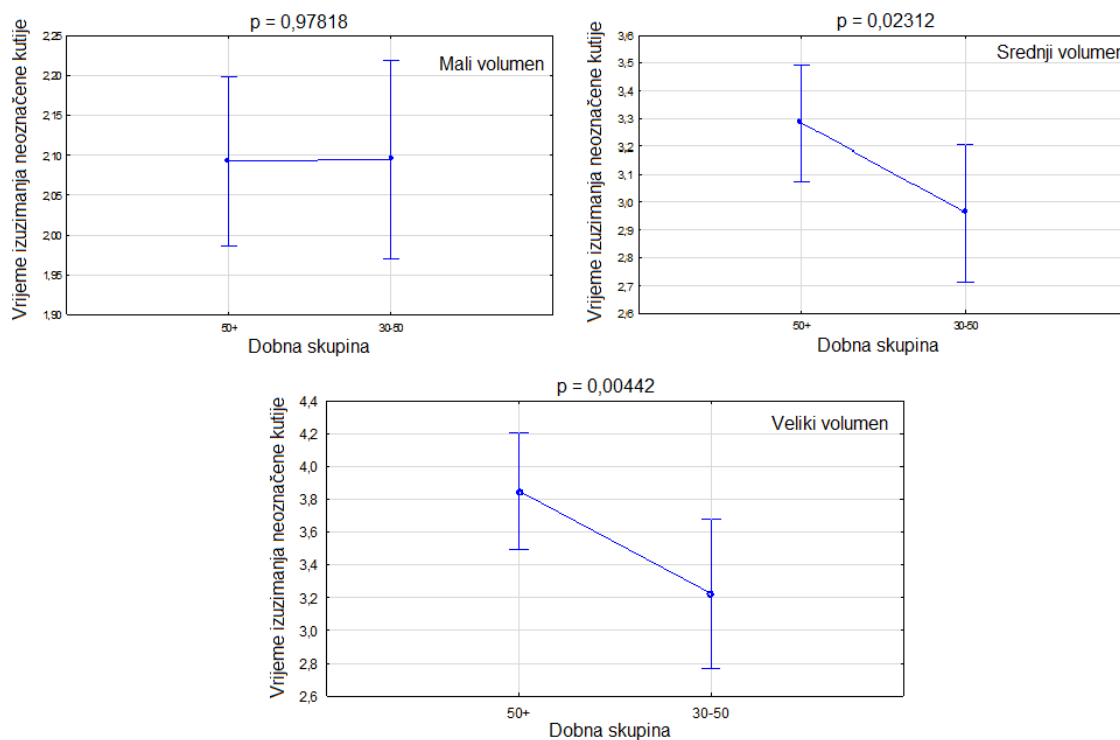
Iz sljedećih grafova vidljivo je da s obzirom na masu postoji značajna razlika između dobnih skupina, što je svakako bilo i za očekivati. Kod tri od četiri razine faktora mase vidljivo je da je dobna skupina 30 do 50 godina je značajno brža u izuzimanju kutija, a to potvrđuje i vrijednost  $p$  manja od 0,5.



**Slika 29. Analiza varijance dobnih skupina kategorizirano po masi**

### 6.3. Usporedba s obzirom na volumen

Kod analize varijance dobnih skupina kategorizirano po volumenu vidimo sljedeće stanje: odzivi imaju gotovo istu srednju vrijednost za mali volumen uz vrlo dobro preklapanje, što potvrđuje iz veličina  $p$  od 0,97818. Srednji i veliki volumen, s druge strane, pokazuju potpuno drugačiju sliku. Skupovi odziva se uopće ne poklapaju uz  $p$  vrijednosti manje od 0,05, što znači da gledano prema kategorijama srednjeg i velikog volumena skupovi imaju značajnu različitost.



Slika 30. Analiza varijance dobnih skupina kategorizirano po volumenu

## 7. ZAKLJUČAK

Provedbom analize podataka dobivenih iz pokusa otkrilo se puno zanimljivih detalja koji bi se daljnjom razradom mogli primijeniti u realnim uvjetima s ciljem optimizacije procesa ručnog komisioniranja uz istovremeno poboljšavanje ergonomije rada zaposlenih u skladištu. Ključni dio analize bio je usporedba rezultata po dobnim skupinama kako bi se vidjelo postoji li značajna razlika u trajanju izuzimanja. Također se promatralo što utječe na vrijeme izuzimanja kod pojedine dobne skupine. Analizom varijance dobnih skupina po svim utjecajnim faktorima dobio se rezultat da postoji značajna razlika u vremenima izuzimanja, što nam govori da su radnici od 50 i više godina u prosjeku značajno sporiji u izuzimanju od radnika starosti između 30 i 50 godina. Razlike su naravno najveće kod velikih masa i na najvišim policama što govori da bi se u vidu poboljšavanja ergonomije u idealnim uvjetima moglo označiti koje mase tereta idu na koje police, no pitanje je kolika je isplativost i provedivost toga u realnom skladištu s mnogo različitih masa tereta i s velikom dinamikom skladištenja i izuzimanja. Sporedni predmet promatranja bila je označenost i neoznačenost kutija koja se pokazala kao moguće rješenje u skladištima u kojima se radi sa velikim volumenima različitih masa. Kada bi kutije imale označene mase tereta radnik bi u prosjeku brže izuzimao kutije velikih volumena zato što ne bi pretpostavljao da se radi o velikim masama tereta.

Sve u svemu, pokus i analiza su pokazali kako postoje mjesta za unaprjeđenje procesa izuzimanja, a samim time i cjelokupnog komisioniranja, u skladištima gdje se rad obavlja ručno. Ovisno o uvjetima pojedinog skladišta u budućnosti ćemo moći vidjeti prilagodbe u izgledu regala, rasporedu odlaganja i izuzimanja robe i demografiji radne snage u skladištima gdje će takva optimizacija procesa donositi značajnu uštedu.

**LITERATURA**

- [1] Slika ustupljena od doc. dr. Brigitte Gajšek sa Sveučilišta u Mariboru
- [2] Internetska stranica Statistics Solutions  
<http://www.statisticssolutions.com/manova-analysis-anova/> (pristupljeno 19.12.2017.)
- [3] doc. dr. Cajner, H.: Inženjerska Statistika – materijali s predavanja, 2015.
- [4] Internetska stranica Stat Graphics  
<http://www.statgraphics.com/regression-analysis> (pristupljeno 19.12.2017.)



---

## **PRILOZI**

I. CD-R disc